T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

FARKLI DEPREM ALGILAMA YÖNTEMLERİNİN GANOS SİSMİK İZLEME VERİSİ ÜZERİNDE ETKİNLİĞİNİN ARAŞTIRILMASI

Başak IŞIK

DANIŞMAN
Prof. Dr. Eşref YALÇINKAYA

Jeofizik Mühendisliği Anabilim Dalı

Jeofizik Mühendisliği Programı

Aralık, 2022

TEZ KABUL VE ONAYI

Başak IŞIK tarafından, **Prof. Dr. Eşref YALÇINKAYA** danışmanlığında hazırlanan **Farklı Deprem Algılama Yöntemlerinin GANOS Sismik İzleme Verisi Üzerinde Etkinliğinin Araştırılması "** başlıklı bu çalışma, jürimiz tarafından **15/12/2022** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Prof. Dr. Eşref YALÇINKAYA İstanbul-Cerrahpaşa Üniversitesi Jeofizik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Ali PINAR Boğaziçi Üniversitesi Deprem Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Tuna EKEN İstanbul Teknik Üniversitesi Jeofizik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. ..... Üniversitesi ..... Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. ..... Üniversitesi ..... Anabilim Dalı		☐ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Başak IŞIK

Canım aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

FARKLI DEPREM ALGILAMA YÖNTEMLERİNİN GANOS SİSMİK İZLEME VERİSİ ÜZERİNDE ETKİNLİĞİNİN ARAŞTIRILMASI

Bu tez çalışması, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 118R019 numaralı projesi ile desteklenmiştir.

TEŞEKKÜR

Tez çalışmam boyunca bana gösterdiği ilgi ve desteğinden dolayı danışman hocam Prof.Dr. Eşref YALÇINKAYA'ya sonsuz teşekkürlerimi sunarım.

Tüm hayatım boyunca koşulsuz yanımda olan ve desteklerini esirgemeyen annem Yıldız IŞIK'a, babam Mehmet IŞIK'a ve kardeşim Gizem IŞIK'a çok teşekkür ederim.

Aralık 2022 Başak IŞIK

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xvi**
SİMGE VE KISALTMA LİSTESİ ..... **xviii**
ÖZET ..... **xix**
ABSTRACT ..... **xxi**
1. GİRİŞ **1**
1.1 DEPREM ALGILAMA YÖNTEMLERİNİN TARİHSEL SÜRECİ 3
1.1.1.Enerji Tabanlı Dedektörler 4
1.1.2. Dalga Formu Benzerliğine (Waveform Similarity) Dayalı Dedektörler 4
1.1.3. Makine Öğrenimi ve Veri Madenciliği 5
1.1.3.1 Gözetimli/Eğitimli (Supervised) Öğrenme 6
1.1.3.2. Gözetimsiz (Unsupervised) Öğrenme ve Veri Madenciliği 8
2. KAVRAMSAL ÇERÇEVE 9
1.2. TEZ ÇALIŞMASININ AMACI VE KULLANILAN VERİLER 9
3. YÖNTEM **15**
3.1 STA/LTA YÖNTEMİ 38
3.1.1 STA/LTA Çalışma Prensibi 38
3.1.2. STA/LTA Parametrelerin Seçimi 39
3.1.3. STA/LTA Yönteminde Kullanılan “CONDET” Programı 44
3.2 FAST (Fingerprint and Similarity Thresholding) 48
3.2.1 Veri Ön İşleme 51
3.2.2. Parmak İzi/Özellik Çıkarımı (Fingerprint Extraction) 51

3.2.3. Benzerlik Arama 57
3.2.4. Benzerlik Arama Çıktısı ve İşlem Sonrası 65
3.2.5 Sonraki adımlar: Benzerlik Eşikleme 66
3.2.6. Bir Sismik Ağ Üzerinden Benzerliğe Dayalı Algılama 66
3.2.6.1. Olay Çifti Çıkarma (event-pair extraction) 69
3.2.6.2. İkili Sözde İlişkilendirme (Pairwise pseudo-association) 74
3.2.6.3. Olay Ayrımı (Event Resolution) 77
4. BULGULAR 79
4.1.STA/LTA ANALİZLERİ 80
4.2 FAST ANALİZLERİ 110
5. TARTIŞMA 141
KAYNAKLAR 147
EKLER 153
İNTİHAL RAPORU İLK SAYFASI 185
ETİK KURUL İZİN YAZISI 186
KURUM İZNİ YAZILARI 187
ÖZGEÇMİŞ 188

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1: MONGAN-1 ağı istasyon dağılımı (üçgenler) ve yüzey jeolojisi. Sadece ağın dış istasyonlarının kodları gösterilmiştir (Yalçınkaya ve diğ., 2020). 10

Şekil 1.2: Çalışma bölgesi ve çevresinin aletsel dönem depremselliği ve ana yapısal unsurlar. Yeşil kalın çizgi 1912 ve 1999 depremleri kırığını temsil eder. Fay boyunca oluşan önemli depremler ve kaynak mekanizma çözümleri gösterilmiştir. Sarı yıldız 13 Eylül 1912 depremi lokasyonunu gösterir (Yalçınkaya ve diğ., 2020).....11

Şekil 2.1: Deprem algılama yöntemlerinin üç nitel metrik açısından karşılaştırması (Yoon ve diğ. 2015): Algılama hassasiyeti (detection sensitivity), genel uygulanabilirlik (general applicability), hesaplama verimliliği (computational efficiency). STA/LTA yöntemi bilinmeyen kaynaklı depremleri bulma ve gerçek zamanlı algılama nedeniyle genel uygulanabilirlik ve hesaplama verimliliği açısından yüksek puan almaktadır. Ancak düşük S/N oranına sahip sismik sinyalleri kaçırması nedeniyle algılama hassasiyeti düşüktür. Şablon eşleştirme (templete matching) düşük S/N oranlarında depremleri bulabildiğinden, algılama duyarlılığında ve hesaplama verimliliğinde yüksek puanlara sahiptir. Ancak önceden belirlenecek olan (şablon dalga formu) gerektiğinden genel uygulanabilirlik puanı düşüktür. Otokorelasyon yüksek algılama hassasiyetine ve bilinmeyen benzer depremleri bulabilmesi nedeniyle genel uygulanabilirliği yüksektir. Ancak sürekli veri kümesinin boyutuyla düşen hesaplama verimliliğine sahiptir. FAST her 3 metriğe göre daha iyi performans gösterir (çapraz korelasyona dayalı algılama duyarlılığı, genel uygulanabilirliği ve yüksek hesaplama verimliliği) (Bergen, 2018'den değiştirilmiştir.). 14

Şekil 3.1: STA/LTA tetikleme hesaplamalarının değişkenleri ve işlevi. a) Sürekli bir sinyal (filtrelenmiş) b) STA, LTA pencerelerinin mutlak ortalamasını gösterir c) STA/LTA oranını gösterir. Ek olarak tetik aktif durum çizgisi (trigger active state) (düz çizgi dikdörtgen ile gösterilmiş), olay sonrası süre (post event time, PET), olay öncesi süre (pre event time, PEM) gösterilmiştir. (Trnkoczy, A. (2009)'dan değiştirilmiştir.).....39

Şekil 3.2: Sismik sinyaldeki 'spike' ve kısa yerel olaylar için tetiklenme hassasiyetinin STA süresinin etkisi. a) Sol tarafta iğnecik şeklinde kayıt görülürken sağ tarafta yerel bir deprem kaydı gösterilmiştir. b) STA, LTA değerleri gösterilmiştir c) STA/LTA oranı ile birlikte olay öncesi süre (PEM), olay sonrası süre (PET) ve aktif durum çizgisi gösterilmiştir. Burada STA/LTA tetik eşik seviyesi 10, tetiklenmeyeceği eşik seviyesi 2 olarak seçilmiştir. 3 sn'lik STA süresi deprem tetiklemiş ancak çok daha büyük genlikli iğnecikleri tetiklememiştir. Böylelikle 3 sn'lik STA süresinde herhangi bir yanlış tetikleme olmamıştır. Alttaki b ve c grafikleri aynı değişkenleri göstermektedir. Ancak burada STA süresi 0.5 sn seçilmiştir. Burada görüldüğü üzere iğnecik tetiklenerek yanlış bir tetiklemeye neden olmuştur (Trnkoczy A.,2009'dan değiştirilmiştir.). 40

Şekil 3.3: Yumuşak sismik sinyalli deprem için tetikleme algoritma hassasiyetine LTA süresinin etkisi. a) P dalgasının ortaya çıktığı bir deprem gösterilmiştir. b)LTA değeri 60 s ve STA 2 s olarak alınmıştır. c)LTA değeri grafikte görüldüğü üzere hızlı bir şekilde değişmemektedir. STA/LTA oranı, STA/LTA tetik eşik seviyesini (trigger threshold level) aşarak normal bir kayıtla sonuçlanmasına izin verdi. d) ve e) grafiklerin de aynı durum 30 sn'lik daha kısa bir LTA süresi seçilerek uygulanmıştır. d grafiğinde görüldüğü üzere LTA değeri uygulamanın ilk başında hızlı arttığından STA/LTA oranının artmasına izin vermemekte ve dolayısıyla STA/LTA oranı, tetik eşik seviyesini (trigger threshold level) aşamadığından tetiklenme meydana gelmemekte ve deprem kaçırılmaktadır (Trnkoczy A.,2009'dan değiştirilmiştir.). 41

Şekil 3.4: Zayıf P dalgasını içeren deprem için tetiklenme algoritma hassasiyetine LTA süresinin etkisi. a) P dalgasından daha büyük dalgaların olduğu bir kayıt verilmiştir. b) STA süresi 1 sn ve LTA süresi 100 sn olarak seçilmiştir. c) görüldüğü üzere seçilen parametrelerin P ve S dalga paketlerini tetiklediği görülmektedir. d) d'de aynı durum için 45 s'lik daha kısa bir LTA süresi seçilmiştir. Grafik e'de görüldüğü üzere S dalgası zar zor tetiklenebilirken, P dalgası hiç tetiklenmemiştir. Bu nedenle kaydedilen veri dosyası ise çok kısa olmaktadır. Ayrıca kaydedilen veri dosyasında P dalgası ve öncesindeki sismik gürültü hakkında bilgi eksik kalmaktadır. Bundan daha küçük depremler kayıt altına alınamamaktadır (Trnkoczy A.,2009'dan değiştirilmiştir.). 42

Şekil 3.5: Sismik gürültü durumunda yanlış tetiklenmeye LTA süresinin etkisi. a)kaydın ortasına doğru artan sismik gürültü görülmektedir. Genliklerin değişimi ani değil yaklaşık 20-30 sn sürmektedir. b ve c 'de LTA süresi 30 sn olarak seçilmiştir. LTA değerinin aşağı yukarı sismik gürültüyü takip ettiği görülmektedir. STA/LTA oranı, STA/LTA tetikleyicisinin altında kalmakta ve önemli ölçüde artan gürültüye rağmen yanlış tetiklenmeye izin vermemektedir. d ve e'de LTA süresi 60 s olarak seçilmiştir. LTA hızlı değişmediğinden gürültü artışı sırasında daha yüksek bir STA/LTA oranına izin verir. Sonuç olarak yanlış bir tetiklenmeye neden olur ve kayıtçının hafızasında gereksiz yer tutmasına neden olur (Trnkoczy A., 2009'dan değiştirilmiştir.). 43

Şekil 3.6: "CONDET" programı giriş parametre dosyası "condet.par"..... 47

Şekil 3.7: FAST algoritmasının çalışma prensibini tanımlayan genel bir bakış (Bergen, 2018'den değiştirilmiştir.). 50

Şekil 3.8: FAST özellik çıkarma aşamaları a) Sürekli zaman serisi verisi b) Spektrogram;log ölçeğinde genlik c) Spektral görüntü d) Haar dalgacık dönüşümü e) Standartlaştırılmış Haar Katsayıları f) İkili Parmak İzi: özellik çıkarma çıktısı (Bergen, 2018'den değiştirilmiştir.). ..54

Şekil 3.9: FAST arama diyagramı. Sürekli veri setinin tamamı için ikili parmak izleri çıkarılır ve ilgili sinyallere karşılık gelenler "veri tabanı parmak izleri" olarak etiketlenir. Etkin arama için karma tablolarda yalnızca "veri tabanı parmak izleri" saklanır. Benzerlik arama adımında, tüm ikili parmak izleri, karma tablolarında saklanan "veri tabanı parmak izlerine" karşı sorgulanır (Bergen, 2018'den değiştirilmiştir.). 58

Şekil 3.10: MinHash fonksiyonu ile parmak izinin Min-Hash Signature (MHS) dönüştürülmesi (Broder ve diğ., 2000). 59

Şekil 3.11: İki benzer deprem için CC ve Jaccard benzerliği. A) İki benzer normalleştirilmiş deprem dalgaformu 2011-01-08 CCOB.EHN sürekli verilerinde 1266.95 s (mavi) ve 1629 s (kırmızı), yüksek CC'ye sahip = 0.9808 (denklem. 3.7), neredeyse mükemmel örtüşüyor. B) Bu dalgaformlarına karşılık gelen parmak izleri de yüksek oranda örtüşür, yüksek bir 0.7544 Jaccard benzerliği ile. Beyaz: her iki parmak izi de 1'dir; kırmızı: bir parmak izi 1 ve diğeri 0; siyah: ikisi de parmak izleri 0. Burada Jaccard benzerliği J(A,B) beyaz elemanların sayısının (burada hem A hem de B parmak izleri 1) beyaz ve kırmızı elemanların toplamına bölünmesine eşittir (burada A veya B 1'dir, ancak ikisi birden değildir) (Yoon ve diğ.,2015'den değiştirilmiştir). 60

Şekil 3.12: LSH'nin parmak izlerini veritabanında nasıl gruplandırdığına dair örnek; A) A ve B iki benzer parmak izinin MHS örneği p=6 B) LSH her karma tablosu (kırımızı kutu) içindeki karma kova (hash buckets) (yuvarlak) benzer iki parmak izinin (A ve B) nasıl yerleştirileceğine karar verir. MHS uzunluğu p = 6 ve b = 3 karma tablosu var böylece her bir karma tablo, 6/3 = 2 olan her parmak izinin MHS'sinin farklı bir alt kümesini alır tamsayılar uzun: r = 2 Min-Hash fonksiyonlarının çıktısı. Her bir karma tablosunu ayrı ayrı alarak: A ve B'nin MHS alt kümeleri eşittir, daha sonra A ve B, veri tabanına aynı karma kovaya girer; bu sırasıyla h(A) = h(B) = [155, 64] ve h(A) = h(B) = [110, 21] olduğu karma tablo 1 ve 3 doğrudur. Şekil 3.12A'da p = 6 olan iki benzer parmak izi A ve B için örnek MHS dizilerini göstermektedir. LSH, her parmak izini veri tabanına eklemek için MHS'yi kullanır. Şekil 3.12B'de Şekil 3.12A'da verilen MHS dizileri kullanılarak her bir karma tablosundaki karma tablolara benzer A ve B parmak izlerinin LSH'la nasıl yerleştirileceğini göstermektedir (Yoon ve diğ., 2015'ten değiştirilmiştir). 61

Şekil 3.13: LSH veri tabanı ve benzerlik arama örneği**.** (A) LSH kullanılarak oluşturulan veri tabanı, b = 3 hash tablosu ile (kırmızı kutular); her hash tablosunda birçok oval şeklinde gösterilen karma kova (hash buckets) bulunmaktadır. LSH yüksek olasılıkla aynı karma kovadaki benzer parmak izlerini gruplamaktadır; deprem sinyalleri (renkli) aynı kova içine girmesi muhtemeldir, buna karşılık gürültü (siyah) farklı kovalara gruplandırılmaktadır. B) sorgu (query)dalga formuna (mavi) benzer veri tabanındaki dalga formlarını aramaktadır. Daha sonra, her karma tabloda aynı kovadaki diğer dalga formlarını almakta ve her dalga formu çifti arasında FAST benzerlik hesaplanmaktadır. Kırmızı dalga formu üç karma tablonun tümünde mavi sorgu dalga formuyla aynı pakettedir. Yani benzerlikleri 1'dir; yeşil dalga biçimi, üç karma tablodan ikisinde aynı kovadadır ve bunun gibi. Bu şekil kolay görselleştirme için dalga formları görüntüleri verilmiştir, fakat veri tabanı deposu karma kova (hash bucket) parmak izleri için referanstır ve bir arama sorgusu dalga formunun parmak izine dönüştürülmesini gerektirir (Yoon ve diğ.,2015'ten değiştirilmiştir.). 62

Şekil 3.14: Jaccard benzerliğinin bir fonksiyonu olarak başarılı bir aramanın teorik olasılığı. Kırmızı eğriler (tüm grafiklerde aynı) şunu göstermektedir: örnek olarak seçilen FAST parametreleri: r = 5 (tablo başına düşen fonksiyon sayısı), b = 100 (toplam karma tablo sayısı) ve v = 19. a) b=100 ve v=19 sabit tutularak r değerleri değiştirilmiştir. r arttıkça eğri sağa kayarken başarılı arama için daha yüksek Jaccard benzerliği gerektirmektedir. b) r = 5 ve v = 19 sabit tutulmuştur. b arttıkça eğri sola doğru hareket etmekte ve daha fazla karma tablo sayısı daha düşük Jaccard benzerliğine sahip parmak izi çiftlerini bulmaya olanak vermektedir. c) r=5, b=100 parametreleri sabit tutularak v değerleri değiştirilmiştir. v arttıkça, eğri daha dik bir eğimle sağa hareket etmektedir ve başarılı arama için iki parmak izi arasında Jaccard benzerliği daha yüksek olmalıdır Ayrıca algılananlar ile algılanmayanlar arasında daha keskin bir ayrım gerekmektedir (Yoon ve diğ., 2015'ten değiştirilmiştir.). 64

Şekil 3.15: Sürekli sismik verinin tek bir kanal için seyrek benzerlik matrisi olarak FAST çıktısının gösterimi. Her kare bir çift parmak izini temsil etmektedir. Matris seyrektir. Çünkü; LSH aramayı oldukça benzer parmak izi çiftleriyle sınırlıyor. Siyah kareler oldukça yüksek benzerliğe sahiptir ve oldukça benzer dalga formlarının oluştuğunu göstermektedir. FAST benzerlik ölçeği aynı karma kovadaki her parmak izi çiftini içeren karma tabloların bir kesridir. Sonraki aşamalarda yinelenen çiftlerin (tekrarlayan çiftlerin) kaldırılması da dahil olmak üzere olay algılamalarının bir listesini elde etmek için işleme ve eşikleme gereklidir.....66

Şekil 3.16: Çok istasyonlu FAST algılama hattının diyagramı. Tek istasyonlu FAST her istasyon için seyrek bir benzerlik matrisi üretmektedir. 1) Olay çifti çıkarma (event-pair extraction) adımında her istasyon için seyrek benzerlik matrisi ikili olay algılama (pairwise event detections) listesine dönüştürülmektedir. 2) ikili sözde ilişkilendirme (pairwise pseudo association) adımında sismik ağda birden fazla istasyonda gözlenen olay çiftlerini tanımlanmaktadır. 3) Olay ayrımı (event resolution) ikili olayları (pairwise event) bir "aday olay algılama" (candidate event detection) listesine dönüştürmektedir (Bergen, 2018'den değiştirilmiştir.). 68

Şekil 3.17: Matristeki gruplara karşılık gelen potansiyel deprem algılamaları (Bergen, 2018'den değiştirilmiştir.). 69

Şekil 3.18: Olay çıkarma modeli: Benzerlik matrisindeki köşegen yapılar tek bir olay çiftinin (event pair) çoklu algılamalarına karşılık gelmektedir. Varış zamanları t1 ve t2 olan olay1 ve olay2 için sırasıyla, parmak izleri (t1 ,t2), (t1+lf, t2+ lf), ve (t1+2lf, t2+2lf) arasında benzeşme (correspondence) vardır. Burada belirtilen lf bitişik kayan pencereler arasındaki zaman gecikmesidir. Üç çift benzer parmak izi çifti için birinci ve ikinci olay çifti arasındaki geçen süre t2 -t1 'dir. Dalga formlarına karşılık gelen normalleştirilmiş çapraz korelasyon (cross correlation) verilmiştir (Bergen, 2018).....70

Şekil 3.19: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: Sol taraftaki paneller tüm parmak izi çiftlerinin mavi renkte tek bir olay çiftine atandığı küçük bir seyrek benzerlik matrisine karşılık gelmektedir (koyu gölgeler daha yüksek benzerliğe karşılık gelmektedir.). Diğer tüm parmak izi çiftleri gri renk ile gösterilmiştir. Sağ panellerde ise seyrek benzerlik matrisi bloğundaki seçilen satır ve sütunlara karşılık gelen iki sürekli dalga formu verisi aralığını göstermektedir. Yukarıdaki örnekler hem birçok benzer parmak izi çifti hem de bazı yüksek benzerlikli parmak izi çiftler ile nispeten güçlü algılamalardır. Yukarıda (d) (PSGCX.BHZ) istasyonunda 1307932 zaman damgası dalga formu 1314899' deki ile benzerdir (mavi renk ile gösterilmektedir.). 1314929 'ki dalga formu ise gri olarak gösterilmektedir (Bergen, 2018'den değiştirilmiştir.). 71

Şekil 3.20: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: daha düşük sinyal gürültü oranına sahip olay- çift algılamaları. Yukarıda verilen örnekler nispeten zayıf algılamalardır. Olay çift çıkarımı bu durumlar için oldukça kullanışlıdır. Çünkü bireysel parmak izlerinin (individual fingerprint) nispeten düşük benzerliğe sahip olmasına rağmen bu olay çiftleri korunacaktır. (a) (PB01.BHZ), (b) (PATCX.BHZ), (c) (PSGCX.BHZ), (d) (PATCX.BHZ) bu olay çifti için yalnızca benzer olarak tanımlanan ilk P varışları (Bergen, 2018'den değiştirilmiştir.). 72

Şekil 3.21: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: yanlış algılamalar. Yukarıdaki algılamalar muhtemel yanlış algılamalardır. Bu algılamalar ikili sözde ilişkilendirme (pairwise pseduciation) ve olay çifti pruning ile elimine

edilecektir. (a) (PB01.BHZ) Olay çifti çıkarma, her köşegen matriste birbirine yakın böyle birden fazla yapılar olsa bile her köşegen yapıyı ayırmaktadır. Bu matris bloğundaki model, 30648-30663 zaman damgalarına (timestamp) karşılık gelen dalga formunun 31269 ve 31314 arasındaki zaman damgalı örtüşen dalga formlarına benzerdir. (b) (PB01.BHZ) nispeten geniş aralıklı olay çiftleri ilişkili gürültü nedeniyle yanlış algılama olma eğilimindedir. Sonuç olarak olay çiftleri için maksimum bir genişlik ayarlanması tavsiye edilmektedir. Böylece yalnızca gerçek algılamaların daha karakteristik olan çapraz yapıları ikili sözde ilişkilendirmeye geçirilmektedir. (c) (PATCX. BHZ) bazı olay çiftleri, kümenin özelliklerine (örneğin genişlik) bağlı olarak ortadan kaldırılabilir, yalnızca kümenin özelliklerine dayanarak doğru tespitleri yanlış tespitlerden ayırt etmek genellikle zordur. İkili sözde ilişkilendirme yoluyla komşu istasyonlardan algılama sonuçları gibi ek bağlam bilgileri, yanlış veri yığınını ortadan kaldırmak için gereklidir (Bergen, 2018'den değiştirilmiştir).....73

Şekil 3.22: Sözde ikili ilişkilendirme için sabit olaylar arası zamanın gösterimi. a) Başlangıç zamanları $t0$ ve $t1$ olan iki olaydan oluşan A olay çifti ele alınmaktadır. $\tau A(q)$, istasyon q'ya P dalga varış süresi olarak kabul edilmiştir. O halde istasyon q'ya varış süreleri $t0+\tau A(q)$ ve $t1+tA(q)$, ağdaki herhangi q istasyonu için olaylar arası süre $dtA = t1-t0$. Aynı mantık sadece P dalgasına değil diğer faz varışlarına uygulanabilmektedir. b) Sabit olaylar arası zaman gereksinimi, bazı kaynak konumlarıyla tutarlılığı doğrulamak için ek bir adım gerekmeden ikili algılamalar olarak ağ üzerinden ilişkilendirilecek olaylara izin veren ek bir kısıtlama sağlamaktadır. Aşağıdaki şemada sadece bir çift olayın (yeşil renk ile gösterilmiştir) benzer bir kaynağı paylaşan her iki olay ile tutarlı ağ üzerinden varış zamanlarına (sabit olaylar arası zaman dtA) sahiptir. İkili sözde ilişkilendirme, varış zamanları nispeten birbirine yakın (seyrek bir ağda bölgesel depremler için <60 saniye) ve olaylar arası süreler istasyonlar arasında neredeyse aynı (FAST parmak izlerinde kullanılan gecikmenin boyutuna bağlı olarak <1-2 saniye içinde) olay-çiftlerini geçici olarak ilişkilendirmektedir (Bergen ve Beroza, 2018'den değiştirilmiştir.). 75

Şekil 3.23: FAST tarafından beş istasyon da tespit edilen, ancak sınırlı zamansal örtüşme olan bir ağ olay çifti örneği. (a) Şili'de Iquique yakınlarında 2014-03-21 tarihinde beş istasyonda gözlemlenen iki olay çifti için dalga formu verisi (gri) gösterilmektedir. Siyah ile gösterilenler FAST tarafından belirlenen benzer dalga formuna sahip kısımlardır. (b) beş istasyondaki tüm için veriler, seyrek ağ benzerlik matrisinde karşılık gelen FAST algılamalar çizilmiştir (Bergen, 2018). Her istasyon için algılamalar farklı renklerde gösterilmiştir. Siyah olarak gösterilen 2 istasyonda parmak izi çifti tespit edilmiştir. FAST tarafından tam olarak 2 istasyonda 11 parmak izi çifti tespit edilirken, 3 istasyonda ise hiçbiri tanımlanmamıştır (Bergen, 2018'den değiştirilmiştir.). 77

Şekil 3.24: Olay ayrımı adımını gösteren şema. Olay çifti çıkarma ve sözde ikili ilişkilendirme adımlarına kadar tüm algılamalar ikilidir (pairwise). Olay ayrımı (event resolution), ikili algılamalar listesini (A, B, C olay çiftleri) bir benzersiz olay listesine (a list of unique events) (olay 1, olay 2, olay 3) dönüştürmektedir (Bergen, 2018'den değiştirilmiştir.).....78

Şekil 4.1: MONGAN -1 ağı istasyon dağılımı (üçgenler) (Yalçınkaya ve diğ., 2020). STA/LTA analizinde kullanılan istasyon lokasyonları ayrıca isimlendirilmiştir. 79

Şekil 4.2: STA/LTA tarafından algılanan bir patlatma kaydı örneği.....91

Şekil 4.3: Çevresel gürültülerden kaynaklı olarak istasyonlar tarafından kaydedilen bir kayıt örneği.....91

Şekil 4.4: Çevresel gürültülerden kaynaklı olarak istasyonlar tarafından kaydedilen bir kayıt örneği. 92

Şekil 4.5: a)2019.01.08 tarihinde saat 10:09:22.7'de istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b)c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S faz işaretlemesi. 93

Şekil 4.6: Kandilli Rasathanesi'ne ait 2019.01.08 tarihli saat 10:09:20 ait RKY istasyonu üç bileşen kaydı. 94

Şekil 4.7: a) c0ATZ istasyonu düşey bileşen kaydı üzerinde otomatik ayıklama ve STA/LTA ile keşfedilen ve b) aynı kaydın kırmızı işaretli alanı içinde manuel keşfedilen ikinci olay. 95

Şekil 4.8: a) 2019.01.09 tarihinde saat 07:00:00'da c0ATZ istasyonu tarafından kaydedilen depremin tetiklenme penceresi b) STA/LTA oran penceresi. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı gösterir 96

Şekil 4.9: Tablo 4.6'da verilen tetiklenen istasyonların STA/LTA grafikleri. 99

Şekil 4.10: c0ATZ istasyonu düşey bileşen kaydı üzerinde manuel olarak keşfedilen ancak STA/LTA ile keşfedilemeyen olay kaydı. 100

Şekil 4.11: a)2019.01.14 tarihinde saat 14:41:00'da istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b) c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S fazlarının işaretlenmesi. 101

Şekil 4.12: Tablo 4.8'de verilen tetiklenen istasyonlar. 104

Şekil 4.13: 2019.01.16 tarihinde saat 08:31:52'de istasyonlara ulaşan depremin görüntüsü. 105

Şekil 4.14: a)2019.01.16 tarihinde saat 08:31:55'te istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b) c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S fazlarının işaretlenmesi. 106

Şekil 4.15: Tablo 4.9'da verilen tetiklenen istasyonların STA/LTA grafikleri. 110

Şekil 4.16: MONGAN-1 ağı istasyon dağılımı (üçgenler) ve yüzey jeolojisi. Sadece ağın dış istasyonlarının kodları gösterilmiştir (Yalçınkaya ve diğ., 2020). 111

Şekil 4.17: 2019.01.11 ve 2019.01.24 tarihlerinde FAST tarafından aralarındaki yüksek benzerlik nedeniyle olay olarak sınıflanan ancak deprem olmayan olay çiftleri (tekrarlayan gürültüler). 113

Şekil 4.18: r=4 v=2 kombinasyonu tarafından tespit edilebilen ancak STA/LTA ile tespit edilemeyen depremlere ait kayıtlar. 122

Şekil 4.19: Sadece r=4 v=2 parametreleri tarafından tespit edilen uzak deprem dalga formları örnekleri. 124

Şekil 4.20: Sadece *r*=4 *v*=2 parametreleri tarafından tespit edilen yakın deprem dalga formu örnekleri. 126

Şekil 4.21:2019.01.20-2019.01.21 tarihlerinde FAST tarafından algılanan depremlerin dalga formları. 134

Şekil 4.22: Şekil 4.20a'da verilen iki depreme ait c0ATW istasyonu düşey bileşen kaydı... 135

Şekil 4.23: STA/LTA tarafından tespit edilmeyen fakat FAST tarafından algılanan uzak depremler. 136

Şekil 4.24: 2019.01.28-2019.01.29 tarihlerinde FAST tarafından algılanan uzak deprem kaydı örnekleri. 137

Şekil 4.25: Şekil 4.24'te verilen depremlerin c0ATV istasyonu düşey bileşen kaydı. 138

Şekil 4.26: FAST tarafından algılanan kataloglarda olmayan yakın deprem dalga formu örnekleri. 139

Şekil 4.27: Şekil 4.26'da verilen depremlerin c0ATV istasyonu düşey bileşen kaydı 140

TABLO LİSTESİ

Sayfa

Tablo 4.1: STA/LTA analizinde kullanılan dokuz istasyona ait koordinat bilgileri.....79

Tablo 4.2: Farklı STA ve LTA pencere sürelerine bağlı olarak elde edilen otomatik ayıklama sonuçları. 80

Tablo 4.3: SEISAN (Havskov ve Ottemoller, 1999) yazılımı içinde kullanılan CONDET programı içinde STA/LTA yönteminde seçilen parametre değerleri…….82

Tablo 4.4: 2019.01.01-2019.01.31 tarihleri arasında STA/LTA tarafından bulunan depremler……..83

Tablo 4.5: "**condet.out**" dosyasında verilen tetiklenen istasyonlar……95

Tablo 4.6: 2019.01.09 tarihli deprem için tetiklenme oranı 3 olarak alındığında tetiklenme meydana gelen istasyonlar kırmızı kare ile işaretlenmiştir……96

Tablo 4.7: "condet.out" dosyasında verilen tetiklenen istasyonlar……101

Tablo 4.8: Filtrenin 5-15 Hz ve tetiklenme oranının 3 seçilmesiyle **condet.out** dosyasında verilen tetiklenen istasyonlar. 101

Tablo 4.9: STA 0.5 s ve LTA 60 s seçilmesiyle **condet.out** dosyasında verilen tetiklenen istasyonlar. 107

Tablo 4.10: FAST analizi için seçilen 7 istasyona ait lokasyon bilgisi. Analizlerde e3754 kodlu istasyonun üç bileşen kaydı kullanılırken, diğer istasyonların sadece düşey bileşenleri kullanılmıştır.....112

Tablo 4.11: Tablo 4.10'da verilen istasyonlardaki sürekli sismik verideki her bileşende depremleri tespit etmek için kullanılan FAST giriş parametreleri……...…116

Tablo 4.12: Bergen ve Beroza'dan (2018) ikili ilişkilendirme ve ağ algılama için giriş parametreleri. 117

Tablo 4.13: *r*=4 *v*=2 parametreleri sonucunda elde edilen olay sayıları……..118

Tablo 4.14: *r*=4 *v*=3 parametreleri sonucunda elde edilen olay sayıları.....……119

Tablo 4.15: *r*=4 *v*=4 parametreleri sonucunda elde edilen olay sayıları. 119

Tablo 4.16: *r*=5 *v*=2 parametreleri sonucunda elde edilen olay sayıları……120

Tablo 4.17: *r*=5 *v*=3 parametreleri sonucunda elde edilen olay sayıları……120

Tablo 4.18: *r*=5 *v*=4 parametreleri sonucunda elde edilen olay sayıları..……121

Tablo 4.19: 2019.01.01-2019.01.31 tarihleri arasında meydana gelen depremler……128

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
Δ	:Episantır uzaklığı
Hz	:Hertz
km	: Kilometre
$\overline{x}$	: ilk gelen sinyal
$\overline{y}$	: son gelen sinyal

Kısaltmalar	Açıklama
AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
BÜ KRDAE BDTİM	: Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü, Bölgesel Deprem-Tsunami İzleme ve Değerlendime Merkezi
MAD	:Medyan Mutlak Sapma
DWT	:Ayrık Dalgacık Dönüşümü
STFT	:Kısa zamanlı Fourier Dönüşümü
LSH	: Locality Sensitive Hashing
MHS	:Min Hash Signature

ÖZET

YÜKSEK LİSANS TEZİ

FARKLI DEPREM ALGILAMA YÖNTEMLERİNİN GANOS SİSMİK İZLEME VERİSİ ÜZERİNDE ETKİNLİĞİNİN ARAŞTIRILMASI

Başak IŞIK

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Jeofizik Mühendisliği Anabilim Dalı

Jeofizik Mühendisliği Programı

Danışman : Prof. Dr. Eşref YALÇINKAYA

Bu yüksek lisans tez çalışmasında Türkiye-Almanya ikili iş birliği ile oluşturulan bir proje kapsamında Ganos Fayı'nın kara segmenti üzerinde toplam 40 adet istasyondan oluşan MONGAN deprem izleme ağından alınan bir aylık veri kullanılmıştır. Veriler geleneksel algılama dedektörlerden biri olan STA/LTA yöntemi ile, yakın zamanda geliştirilen ve bir tür veri madenciliği yöntemi olan FAST algoritması kullanarak işlenmiştir. STA/LTA enerji tabanlı bir yöntemdir ve dalga varışlarıyla ilişkili sinyal enerjisindeki artışa bağlı olarak sismik dalganın başlangıcını belirlemek amacıyla kullanılır. FAST algoritması ise benzer kaynaklara sahip depremlerin benzer dalga formları üretme eğiliminde olduğu gözlemine dayanan, algılama için temel olarak benzerliği kullanan bir dedektördür.

Amacımız bu veriler üzerinde deprem ayıklama yöntemlerinden olan STA/LTA ve FAST algoritmalarını uygulayarak veriler için en iyi sonucu verecek olan parametreleri ortaya koyabilmektir. Bu tez çalışmasında STA/LTA yöntemi kullanarak otomatik ayıklama işlemine tabi tutulan bir aylık sürekli veri ile manuel ayıklama arasında, kullanılan parametre değerlerine bağlı olarak %51'e varan farklılıklar ortaya çıkmıştır. Bunların bir kısmı otomatik ayıklamanın yakalamadığı olayların eklenmesi şeklinde iken, diğer kısmı ise yanlış tetikleme nedeniyle olay silme şeklindedir. Yapılan ekleme ve silme işlemlerinin sonucunda çalışılan süre içinde tespit edilen net olay sayısı 262'dir. STA/LTA yönteminde en yüksek hatalar daha uzun pencere süreleri (STA=0.5 s, LTA=60 s) ile yapılan algılamada ortaya çıkmıştır (%51.65). Daha düşük

hatalar ise (%32.04) kullanılan daha kısa pencere süreleri ile (STA=0.3 s, LTA=30 s) elde edilebilmiştir. STA/LTA yöntemi kullanılarak hatalı tespit edilen olaylardan önemli bir kısmı deprem olmayan (patlatma veya yüksek enerjiye sahip endüstriyel faaliyetler) kayıt formlarıdır. Bu sonuçtaki önemli etkenlerden biri kullanılan MONGAN sismik ağında istasyonlar arası mesafelerin oldukça küçük olmasıdır (25m-4km). Bu durumda lokal-endüstriyel sinyaller birden fazla istasyonda yaklaşık aynı zamanda kaydedilebilmekte ve ortaya çıkan yüksek ve keskin genlikler STA/LTA yöntemiyle deprem olarak algılanabilmektedir. Diğer hatalı keşif nedenleri arasında; uzun süreli depremlerde ikinci bir tetiklenme (P ve S tetiklenmeleri), farklı frekans aralıklarında çevresel gürültülerin sinyal enerjisini gölgelemesi, mevsimsel ve hava şartları nedeniyle ortaya çıkan enerji formları sayılabilir. STA/LTA dedektörü tarafından yeterli enerjiye sahip yakın depremlerin rahatlıkla tespit edilebildiği görülmüştür. STA/LTA tarafından kaçırılan depremlere bakıldığında önemli bir kısmının uzak depremler olduğu görülmüştür. Ancak bu depremler kullanılan farklı STA/LTA parametre değerleri ile yapılan otomatik ayıklamada keşfedilebilmişlerdir. Yapılan otomatik ayıklamada 262 depremden 75'nin yakın, 187'si uzak depremlerden oluşmaktadır. 262 depremin 124 tanesi ulusal kataloglarda yer alırken 138'i kataloglarda yer almamaktadır. Katalogda yer alan depremlerin büyüklükleri $1.1<M_l<4.3$ arasında değişmektedir.

Tez çalışmasında FAST algoritmasını çalıştırmak amacıyla sanal bir bilgisayar üzerinde 9 GB RAM'a sahip bir Linux işletim sistemi kurulmuştur. Ancak FAST için Linux işletim sisteminde en az 64 GB RAM gerekmektedir. Bu durum karşısında bir aylık sürekli veri, 2 günlük bölümler halinde çalıştırılabilmiştir. FAST ile yapılan algılama sonuçlarına göre en fazla benzer dalga formuna sahip deprem sayısının r=4 v=2 parametre değerleriyle elde edildiği görülmüştür. Bu durumda diğer parametre kombinasyonları ile tespit edilemeyen 31 adet deprem tespit edilebilmiştir. Toplamda 1 aylık süre içinde FAST tarafından 114 adet deprem algılanmıştır. Yapılan katalog taramasında 114 depremin 49'u katalog da yer alırken, 65'i katalogda bulunmamaktadır. STA/LTA tarafından tespit edilemeyen gürültü içindeki 6 deprem FAST tarafından tespit edilebilmiştir. FAST'in verimli kullanımı için, parmak izi üretme ve benzerlik araştırma parametrelerinin uygun ayarlanmasının yanı sıra, benzer gürültü formlarının hatalı algılamaları arttırmaması açısından uygun istasyon dağılımı ve uygun frekans filtrelerine ihtiyaç vardır.

Aralık 2022 , 187 sayfa.

Anahtar kelimeler: Deprem ayıklama, STA/LTA, Makine Öğrenmesi, Veri Madenciliği, FAST

ABSTRACT

M.Sc. THESIS

INVESTIGATION OF EFFECTIVENESS OF DIFFERENT EARTHQUAKE DETECTION METHODS ON THE SEISMIC MONITORING DATA OF THE GANOS FAULT

Başak IŞIK

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Geophysical Engineering

Geophysical Engineering

Supervisor : Prof. Dr. Eşref YALÇINKAYA

In this master's thesis study, one-month long data extracted from the continues digital waveform recordings of the temporary MONGAN seismic network consisting of 40 land stations located in/around the GANOS Fault segment of the North Anatolian Fault Zone (NAFZ) was used within the scope of a project initiated by Turkey- Germany bilateral cooperation. We first processed the data by employing the STA/LTA method, which is known as one of the traditional detection algorithms. Later we tested rather new algorithm named Fingerprint and Similarity Thresholding (FAST), which was recently developed as a type of data mining method. STA/LTA is an energy-based method and is used to determine the onset of a seismic wave depending upon changes (increasing) in signal energy associated with wave arrivals. The FAST acts as a detector that simply benefits from the idea of similarity based on the observations of earthquakes with similar sources tending to generate similar waveforms and uses similarity as the basis for detection.

Our main aim in the present thesis work is to reveal the detection algorithm parameters that will give the optimum performance for the data following a comparison among manual, the STA/LTA and FAST–derived efforts. Our results show that differences up to 51% depending on the selected parameter values have emerged between manual detection and STA/LTA algorithm of one month of continuous data. Some of these differences identify the events that cannot be detected by automatic algorithms, while the other part originates from the false triggering. As a result of this, we detected 262 events in total. The highest error (51.65%) in the STA/LTA method was observed when a longer window length (STA=0.5 s, LTA=60 s) was used. Relatively small errors (32.04%) using STA/LTA was obtained with shorter window

lengths (e.g. STA=0.3 s, LTA=30 s). An important portion of incorrect earthquake detections among entire detected for the STA/LTA method are waveform recordings of non-earthquake activities (blasting or industrial activities with high energy). Relatively small inter-station spacing (4km-25km) of the MONGAN seismic network has mainly enabled notable recordings of local-industrial activities at multiple stations thus leading to the detection of high and sharp amplitude observations via STA/LTA method. Other reasons for these incorrect detections involves; a second trigger (P and S triggers) in long-term earthquakes, the insignificant signal energy masked by environmental noises in different frequency ranges, and the energy forms likely observed due to seasonal and weather conditions. We have observed that the STA/LTA detector can easily detect closely located earthquakes with sufficient energy. Significant amount of earthquakes missed in the STA/LTA algorithm consists of distant earthquakes outside our network. However, these earthquakes could be discovered in automatic detection with different STA/LTA parameters. During the automatic detection, only 75 out of the 262 earthquakes consisted of local seismicity while the remaining part was related to the distant earthquakes. 124 out of the 262 earthquakes were already detected and relocated by the national monitoring centers thus available in the catalogues with the event magnitudes varing between $1.1<Ml<4.3$.

The FAST algorithm was run on a Linux operating system with 9 GB of RAM installed on a virtual computer. However, the FAST required at least 64 GB of RAM in the Linux operating system. Under this constraint, we partitioned one-month long data into 2-days long sections. According to the detection results achieved from the FAST, maximum 31 earthquakes with the most similar waveforms was obtained when r=4 and v=2 were chosen. In total, 114 earthquakes were detected by FAST within a month and only 49 out of these 114 earthquakes were available in the national catalog. We also noted that the FAST was able to detect 6 earthquakes masked by the noise that otherwise could not be detected by STA/LTA. Efficient use of the FAST requires proper tuning of fingerprint generation and similarity research parameters, as well as appropriate station distribution and appropriate frequency filters so that similar forms of noise do not increase false detections.]

January 2022, 187 pages.

Keywords: Earthquake Detection, STA/LTA, Machine Learning, Data Mining, FAST

1. GİRİŞ

Günümüzde üç bileşenli sensöre sahip farklı sismik ağlarda yıllarca süren sürekli sismik veri akışları kaydedilmektedir. Artan veri miktarıyla yüksek miktarda veri setleri ortaya çıkmaktadır. Üretilen bu büyük veri miktarı sismik olayların tespit edilmesini zorlaştırmaktadır. Bu nedenle verilerde var olan deprem sinyallerini tespit edecek otomatik deprem algılama yöntemlerinden faydalanılmaktadır.

Standart deprem izleme sistemleri depremlerin otomatik tespiti, konumu ve karakterizasyonu dahil olmak üzere birçok süreç adımını içermektedir. Otomatik deprem algılama genellikle her istasyondaki sürekli veri için ayrı ayrı uygulanmaktadır. Birinci aşama da olay tespit edilirken ikinci aşama da P ve S dalgalarının varış zamanları işaretlenir. Tek istasyon verilerinden zayıf deprem sinyallerini algılama ve doğruluma zor olabilmektedir. Bu nedenle depremlerin yerlerinin ve karakter özelliklerinin doğruluğu birden çok istasyon ile geliştirilebilinir. Sonuç olarak deprem algılama algoritmaları tipik olarak bir sismik ağda yer alan birden çok istasyondaki verileri ortaklaşa kullanarak çalışır. Bu süreç ilişkilendirme olarak da adlandırılmaktadır (Bergen, 2018).

Otomatik deprem algılama yöntemleri iki sınıfa ayrılmaktadır: veri akışı için gerçek zamanlıya yakın algoritmalar ve önceden toplanmış küçükten büyüğe veri hacimleri için geriye dönük işleme algoritmaları. Gerçek zamanlıya yakın sistemlerde algoritmalar olayın başlangıç zamanından saniyeler ve dakikalar sonra bir belirleme yaparak meydana geldikçe tespit etmeye devam etmektedir. Deprem katalogları genel olarak gerçek zamanlıya yakın algoritmalar kullanılarak üretilmektedir. Ancak herkesin kullanımına açık kataloglardaki daha küçük büyüklükte olayları tanımlamak için ilgilenilen bölgedeki veri arşivlerini yeniden proses etmeleri yaygındır (Bergen, 2018). Bölgesel veya küresel sismik ağlar tarafından oluşturulan deprem katalogları tipik olarak orta ve büyük magnitüdlü (>M4-5) olaylar açısından tam olurken, daha küçük magnitüdlü olaylar için eksik olduğu bilinmektedir. Bu küçük olaylar hissedilemeyecek ya da altyapı hasarına neden olamayacak kadar çok küçük olmalarına karşın, deprem süreçleri ve deprem tehlike hesaplamaları açısından takip edilebilmeleri son derece önemlidir. Daha eksiksiz kataloglar ile aktif bir sismik bölgedeki bir fay boyunca meydana gelen sismik aktivitenin daha iyi anlaşılması sağlanmış olacaktır. Örneğin Shelly ve diğ., (2007) yaptığı çalışmada zayıf sinyalleri algılayan dalga formu benzerliğine dayalı bir yöntem

(templating matching) ile tektonik tremor ve yavaş depremler arasındaki ilişkiyi ortaya koymuştur (Bergen, 2018).

Otomatik deprem algılama sismolojinin temel araştırma alanlarından biridir, fakat karşılaştığı birçok problem bulunmaktadır. Aşağıda deprem algılama yöntemlerinin karşılaştığı bazı problemler ve algılama algoritmaları için gereksinimlerden bahsedilmiştir:

Karmaşık olay dizileri: Sismik aktivitenin yoğun olduğu periyod boyunca meydana gelen depremler bilimsel ilgi konusudur. İdeal deprem algılama yöntemleri öncü şok dizileri, artçı şok dizileri, volkanik- tektonik deprem sürüleri ve yavaş depremler gibi karmaşık olay dizileri boyunca meydana gelen olayları tanımlayabilmektedir. Ancak bu kompleks olay dizilerinin eş zamanlı veya zaman içinde birbirine yakın sürelerde meydana gelmesi durumunda olayların tespit edilmesi zorlaşmaktadır.

Yerel gürültü kaynakları: Sismometreler deprem sinyallerinin yanında yerel gürültü kaynaklarını da kaydetmektedir. Kaydedilen gürültü kaynakları yanlış algılamalar ve yanlış seçimler (piklemeler) üretebilmektedir. Yerel gürültü kaynaklarına ek olarak taş ocağı patlatmalar ve toprak kaymaları da bölgesel ve küresel ölçekte yanlış algılamalar üretebilmektedir. Deprem algılama yöntemleri diğer kaynaklar nedeniyle meydana gelebilecek aşırı yanlış algılamalara maruz kalmadan sismik olayları tespit edebilmelidir.

Nadir olaylar ve dengesiz veri kümeleri: Sürekli veri setlerinde sürekli kaydedilen sinyallerin küçük bir yüzdesini temsil eden ve nispeten az sıklıkta meydana gelen depremlerde gürültü baskındır. Sonuç olarak bir deprem algılama yöntemi mümkün olduğunca deprem sinyallerini tespit ederken yönetilebilir bir yanlış algılama oranını korumalıdır.

Eksik veya düşük kaliteli veriler: Deprem algılama algoritmaları gerçek sensörler tarafından kaydedilen veriler üzerinden çalışmaktadır. Sensörlerde meydana gelebilecek arazılar düzensiz ve kalitesi düşük sinyaller kaydedilmesine neden olabilmektedir. Deprem algılama algoritmaları bu durum karşısında güvenilir olmalıdır.

Büyük ve büyüyen veri hacimleri: Son yıllarda mevcut dalga formu verileri hızla büyümektedir. Deprem sismolojisinde bu büyük verilerin kullanabilirliği hem bir zorluk hem de bir fırsat sunmaktadır. Daha iyi algoritmalar büyük hacimli verilerde yeni yararlı bilgiler elde etmeyi mümkün kılabilir, ancak bu ölçekte uygulanabilecek algoritmaların geliştirilmesi gerekmektedir.

1.1 DEPREM ALGILAMA YÖNTEMLERİNİN TARİHSEL SÜRECİ

İlk matematiksel tabanlı sinyal dedektörlerinden biri Freiberger (1963) tarafından önerilmiştir. Freiberger (1963) Gaussian gürültüsündeki Gaussian sinyallerinin ayıklanması için spektral yoğunluklarının yaklaşık bir karşılaştırmasını uygulamıştır. Bu yöntem sinyallerin başlangıç zamanlarını ölçmekten ziyade sinyalleri ayıklamak için uygundur (Küperkoch ve diğ., 2011).

Stewart (1977) Kaliforniya'daki yerel sismik olayları analiz etmek amacıyla P fazı algılama için otomatik bir prosedür geliştirmiştir. Orijinal sismik izde "hareketli zaman gürültü ortalamalarını" hesaplamak için üç hareketli pencere kullanılarak sismik istasyonunun kabul edilebilir gürültü sınırları içinde çalışıp çalışılmadığı test edilmiştir. Eğer eşik, gürültü seviyesinin 2.9 katını aşıyor ise bir P fazı tespit edilmektedir (Küperkoch ve diğ., 2011).

Gofart ve Herrin (1981) saniyede 20 örnekle örneklenmiş kısa periyodlu bir veri için Walsh dönüşümüne dayalı bir otomatik sismik sinyal algılama algoritmasını geliştirmiştir. Fourier dönüşümüne oldukça benzeyen bu algılama dedektörü hesaplama açısından daha ergonomiktir.

Michael ve diğ., (1982) MIT sismik ağı için gerçek zamanlı bir dijital sismik olay algılama ve kayıt sistemi geliştirmişlerdir (Küperkoch ve diğ., 2011). Sistem, düşük doğal sismik aktiviteye sahip bir ortam ve hava koşulları, kültürel gürültüden etkilenen yüzey istasyonları için geliştirilmiştir (Michael ve diğ., 1982).

Küperkoch ve diğ., (2011) çalışmasında Joswig'in (1987) spektrogramlardaki karakteristik olay özelliklerini kullanan bir model tanımlama tekniği önermiştir.

Otomatik faz başlangıcını belirlemeye yönelik ilk adım Allen (1978, 1982) önerdiği algoritmadır. Allen (1978) seçicinin uygulandığı bir sismik izin lineer olmayan dönüşümlerinden kaynaklı karakteristik fonksiyon (CF) kavramını tanıtmıştır. Allen (1978)'in karakteristik fonksiyonu sismogramın yaklaşık kare zarf fonksiyonunundan hesaplanan kısa süreli ortalama (STA) ile uzun süreli ortalamaların (LTA) oranına (STA/LTA) dayanmaktadır (Küperkoch ve diğ., 2011).

Baer ve Kradolfer (1987) hem yerel hem de telesismik depremlerin P fazı varışlarına duyarlı fakat patlatma gürültülerini ve geçici olayları reddeden otomatik bir algılama algoritması geliştirmişlerdir. Allen (1978)'in zarf fonksiyonunu değiştirerek dinamik bir sinyal eşiği eklemişlerdir. Küperkoch ve diğ., (2011) ve Saragiotis ve diğ., (2002) otomatikleştirilmiş sistemler için daha yüksek dereceli istatistiklere dayalı bir algoritma sunmuşlardır. Algoritma

yerel ve bölgesel sismik olayların P başlangıçlarını otomatik belirlemektedir (Küperkoch ve diğ., 2011).

Zaman ve frekans alanındaki bu yaklaşımların yanısıra model yönelimli algoritmalarda oldukça yaygın kullanılmaktadır. Otoregresif yaygın kullanılan yöntemlerden biridir. Takanami ve Kitigawa (1988) tarafından Akaike Bilgi Kriterine (AIC) dayanarak, sismograma yerel olarak durağan bir otoregresif modelin uydurulması için bir prosedür geliştirmiştir. Bu prosedürü bir online sisteme uygulayarak FUNIMAR (fast univariate case of minimum AIC method of AR model fitting) olarak adlandırmışlardır (Küperkoch ve diğ., 2011).

Leonard ve Kernett (1999) önceki gürültüye kıyasla sinyalin daha karmaşık olması nedeniyle AR modeli sırasındaki artışları tespit etmesi için bir otoregresif yöntem geliştirmişlerdir. Gentilini ve Michelini (2006) yenilikçi sinir ağı modeli (IUANT2) olarak adlandırılan P ve S faz başlangıç zamanını belirlemesi için yapay bir sinir ağı yaklaşımını önermişlerdir (Küperkoch ve diğ., 2011).

1.1.1.Enerji Tabanlı Dedektörler

Genelde STA/LTA algoritmasına dayanan enerji tabanlı yöntemler, depremleri belirlemede etkili yöntemlerden biridir. Bu yöntem sismik dalganın geliş zamanındaki sinyal enerjisi artışına bağlı olarak sismik dalganın başlangıcını belirlemektedir. Enerji dedektörleri sinyal hakkında temel bilgileri kullanmaktadır. Yöntemin basit yaklaşımı onu hesaplama açısından verimli kılmaktadır. Bu yöntemde ardışık iki hareketli penceredeki sismik sinyalin mutlak genliklerinin ortalama değerleri hesaplanmaktadır. STA (short time window) sismik olaylar için hassasken LTA (long time window) sahadaki sismik gürültünün zamansal genliği hakkında bilgi sağlar. Her ikisi de önceden belirlenen bir eşik seviyesini aştığında, sismik olay bildirilir ve veriler dosyaya kaydedilmeye başlar. STA/LTA dedektörleri impulsive depremleri (P ve S varışlarındaki yüksek sinyal gürültü oranı) başarılı şekilde tanımlayabilirken, düşük sinyal/gürültü (S/N) oranlarında, yumuşak (emergent) dalga fazı başlangıçlarında, örtüşen olaylarda, kültürel gürültü, seyrek istasyon aralığı gibi değişen durumlarda depremleri algılayamaz veya yanlış tetiklenmeler üretebilir. Bu açıdan STA/LTA dedektörleri nispeten düşük algılama hassasiyetine sahiptir (Yood diğ., 2015). Bu nedenle düşük magnitüdlü olaylar genel olarak deprem kataloglarında eksiktir.

1.1.2. Dalga Formu Benzerliğine (Waveform Similarity) Dayalı Dedektörler

Deprem kataloglarındaki düşük magnitüdlü depremleri tamamlamak ve aynı zamanda enerji tabanlı dedektörlerin düşük sinyal/gürültü oranına sahip dalga formları veya keskin

(impulsive) olmayan varışları algılamalarındaki zorluklarının üstesinden gelmek için dalga formu benzerliğine (waveform similarity) dayalı hassas bir algılama dedektör olan "şablon eşleştirme- template matching" geliştirilmiştir. Dalga formu çapraz korelasyonu (waveform cross correlation) olarak da bilinen şablon eşleştirme ya da 'matching filtering' algoritması, sinyaller arasındaki benzerliği dalga formu şablonları kullanarak ölçen bir çapraz korelasyon tekniğidir.

Şablon eşleştirme gürültülü verilerde bilinen bir sismik sinyali bulmak için kullanılabilecek hassas ve ayırt edici bir yöntemdir. Ancak bu yöntem öncelikli bir dalga formu şablonu gerektirmesi uygulanabilirliğini azaltmaktadır. Şablonlar genellikle kataloglardaki deprem dalga formlarından ya da insan kaynaklı sürekli verideki impulsive olay dalga formları seçilerek çıkarılmaktadır.

Bu yöntemde şu varsayıma dayanmaktadır; deprem sinyalleri, bilinen şablon olayların dalga formlarına benzerlikleri ile belirlenmektedir. Normalleştirilmiş çapraz korelasyonla ölçülen dalga formu benzerliği olayların benzer kaynak konumları ve kaynak mekanizmaları paylaştığını göstermektedir. Ancak bu şablon tabanlı yöntemlerin hiposantr ve kaynak mekanizmaları şablonlarınkine benzer olmayan depremleri tanımlamada sınırlı potansiyeli vardır. Pearson iki sinyal arasındaki çapraz korelasyonu denklem 1.1'deki gibi tanımlamaktadır:

$$r = \frac{\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i-\bar{x})^2(y_i-\bar{y})^2}} \tag{1.1}$$

$\bar{x}$ = ilk gelen sinyal

$\bar{y}$= son gelen sinyal

1.1.3. Makine Öğrenimi ve Veri Madenciliği

Araştırmacılar, deprem algılama ve sismik sinyallerin sınıflandırılmasındaki sınırlı bir temelde makine öğrenimi tekniklerinden yararlanmaktadırlar. Bilgisayar biliminde ortaya çıkan büyük veri setlerini işlemek için geliştirilen yeni algoritmalar ve büyük hacimli sismik veri setleri sismolojide veriye dayalı keşifler için yeni fırsatlar yaratmıştır. Sismoloji topluluğu deprem algılama ve analiz süreçlerine son zamanlarda makine öğrenimi ve veri madenciliğini entegre etmektedir.

1.1.3.1 Gözetimli/Eğitimli (Supervised) Öğrenme

Gözetimli öğrenme algoritmaları işaretlenmiş eğitim verilerini kullanarak, bir işaret veya hedef değere karşılık gelen bir veri vektörüne eşleyen bir model yaratmaktadır. Deprem algılama bağlamında gözetimli öğrenme algoritmaları, deprem dalga formlarını gürültüye karşı karakterize etmek amacıyla genel bir model öğrenme için bilinen deprem dalga formu (eğitim verisi) örneğini kullanmaktadır. Spesifik olarak gözetimli öğrenme algoritması, dalga formunun bir deprem veya gürültü olup olmadığını gösteren bir etikete eşleyen bir fonksiyonu öğrenmektedir. Denetimli öğrenme algoritmasının şablon eşleştirme gibi geleneksel sinyal işleme tekniklerine göre avantajı yeni örnekleri genelleme yetenekleridir. Bu yüzden gözetimli öğrenme ile deprem algılama daha önceden bilinmeyen kaynaklı deprem sinyalleri belirleme potansiyeline sahiptir. Şablon eşleştirme gözetimli öğrenme tekniğinden ziyade bir sinyal işleme tekniği olarak daha uygun şekilde kategorize edilmektedir (Bergen, 2018). Ancak dalga formlarını deprem veya gürültü olarak sınıflandırmak için bir dizi işaretlenmiş örneklere bağlı olması bakımından bir gözetimli sinyal işleme tekniği olarak düşünülebilinir. Tipik gözetimli öğrenme algoritmalarının aksine şablon eşleştirme yalnızca algılama modelinde bir sınıftan örnekler kullanmaktadır ve sınırlı genelleme yeteneğine sahip olan şablon eşleştirme yalnızca şablon dalga formlarına yüksek benzerlik gösteren dalga formlarına sahip yeni olayları belirleyebilmektedir.

Deprem sismolojisinde olay algılama için gözetimli öğrenme tekniklerini kullanmayı amaçlayan bir dizi araştırma çalışması yapılmaktadır. Örneğin Joswig (1990) tarafından "sonogram dedektör" olarak isimlendirilen bir örüntü tanımlama sistemi geliştirmiştir. Bu sistem bilinen deprem ve gürültü sinyallerinden oluşan eğitim veri setindekilerle ilişkili sürekli dalga formu verilerindeki spektrogram özellikleri ile ilişkilendirilen deprem tespitleri için kullanılmaktadır (Bergen, 2018).

Olay algılama ve faz seçimi için yapay sinir ağ (ANN) (Haykin, 1998) çalışmaları da mevcuttur (Sereno ve Patnaik, 1993; Dai ve MacBeth, 1995, 1997; Wang ve Teng, 1997; Tiira, 1999; Zhao ve Takano, 1999; Gentili ve Michelini, 2006). ANN; taş ocağı patlamaları, sualtı patlatmaları (Del Pezzo ve diğ., 2003), kimyasal patlatmalar (Dysart ve Pulli, 1990) ve heyelanlar (Esposito ve diğ., 2006) dahil diğer olay türlerinden depremleri ayırt etmek için sinyal sınıflandırması için kullanılmıştır (Scarpetta ve diğ., 2005). Çoğu çalışma, sürekli veriden ziyade daha önceden tetiklenmiş verileri kullanarak sonuçları sunan faz seçme veya sinyal sınıflandırma görevleri için ANN uygulamaya odaklanmıştır. Bu çalışmalar yalnızca tek bir gizli katman veya nispeten az sayıda sığ sinir ağları kullanmaktadır. Sonuç olarak alan

bilgisine dayalı zaman ve/veya spektral alanda çıkarılan elle tasarlanmış özellikleri kullanmaya eğitimlidirler ve onlarca ile yüzlerce işaretlenmiş dalga formlarından nispeten küçük eğitim setlerini kullanmaktadır.

Hidden Markov modelleri (HMM) sıralı verileri modellemek ve konuşmaları metne çevirmede kullanılan yaygın bir tekniktir (Rabiner, 1989). HMM volkanik sinyaller (Ohrnberger, 2001; Beyreuther ve diğ., 2008), bölgesel depremler (Beyreuther ve Wassermann, 2008) ve tetiklenmiş depremlerin (Beyreuther ve diğ., 2012) algılanması ve sınıflandırılması için sürekli verilere uygulanmaktadır. Dynamic Bayesian networks (DBN) HMM genelleştirilen başka bir grafik model türüdür ve aynı zamanda deprem algılama için kullanılmıştır (Riggelsen ve diğ., 2007). Riggelsen ve Ohrnberger (2014) sürekli verilerde gerçek zamanlı algılama için üç bileşenli DBN tabanlı algoritmayı uyarlamayı önermiştir. Ancak yöntemlerinin performansını değerlendirmek için bir zorluk olarak kesin referans eksikliğini belirtmektedirler.

Gözetimli makine öğrenimini deprem algılama ve sinyal sınıflandırmaya uygulayan çalışmaların çoğu tek bir kanal veya istasyondan gelen veriler üzerinde çalışmak üzere tasarlanmıştır. Reynen ve Audet (2017) olay tespiti ve sınıflandırması için lojistik bir regresyon ve sismik ağdaki her istasyondan gelen sınıf olasılıklarını hesaba katan özel bir ilişkilendirme algoritması kullanan bir algoritma tanıtmıştır. Draelos ve diğ., (2018) komşu istasyonlarda gözlemlere dayalı tek istasyonlu dedektörler için pekiştirmeli bir öğrenmeye dayalı dinamik eşik seçimi yaklaşımı geliştirmiştir.

Son yıllarda deprem algılama için daha karmaşık sinir ağı mimarilerinin benimsendiği görülmektedir. Wiszniowski ve diğ., (2014) sıralı veriler için bir tür sinir ağı olan tekrarlayan bir sinir ağı kullanan gerçek zamanlı bir algılama algoritmasını tanıtmıştır. Son zamanlarda yapılan birkaç çalışma, olay algılama (Wu ve diğ., 2017; Perol ve diğ., 2018; Wu ve diğ., 2018) ve faz seçme problemlerine (Zhu ve Beroza, 2018; Ross ve diğ., 2018) derin sinir ağları (LeCun ve diğ., 2015) uygulamıştır.

Derin öğrenme modelleri olarak da adlandırılan derin (çok katmanlı) sinir ağları geleneksel sığ sinir ağlarından daha fazla parametreye sahiptirler ve genellikle eğitim için çok sayıda işaretlenmiş örnek (binlerce ila on binlerce şablon dalga formu) gerektirmektedir. Derin öğrenme yöntemlerinin en önemli avantajlarından biri hem özellik çıkarma hem de tahmin geliştirebilmeleridir; bu ise yapay sinir ağları kullanan önceki çalışmalarda olduğu gibi elle tasarlanmış özelliklerin kullanımına güvenmek yerine, sınırlı ön işlemeyle verilere

uygulanmasına izin vermektedir. Fakat daha büyük işaretlenmiş veri kümelerini gerektirmektedir.

Gözetimli öğrenme algoritmaları bilinmeyen kaynakları önceden tespit edebilmek için şablon eşleştirmeden daha iyi genelleme yapabilirken, bu yöntemlerin performansı da eğitim için kullanılan veri setinin niteliği ve niceliği ile sınırlıdır. Makine öğrenimi modellerinin, eğitim verilerindeki herhangi bir yanılmayı tekrarlaması muhtemeldir, bu nedenle eksik veya yanlış işaretlenmiş eğitim verileri (örneğin eğitim seti dışında bırakılan veya yanlış bir şekilde gürültü olarak işaretlenen zayıf depremler) bu tekniklerin performansına zarar verebilmektedir. Gözetimli öğrenme yöntemleri ve şablon eşleştirmenin ortak zayıf noktaları yöntemlerle kullanılabilir şablon dalga formlarının kalitesi ve çeşitliliğinin sınırlı olmasıdır.

1.1.3.2. Gözetimsiz (Unsupervised) Öğrenme ve Veri Madenciliği

Gözetimsiz öğrenme teknikleri etiket/işaret bilgisi olmadan veri kümelerinin yapısını ve örüntüsünü öğrenen bir yöntemdir. Gözetimsiz öğrenme boyutluluğu azaltma, kümeleme ve özellik öğrenme görevlerini içermektedir. Bu yöntemin uygulamalarının çoğu farklı sinyal türlerini ayırt eden olay dalga formları arasındaki ilişkiyi analiz etmek veya özellik seçimi gibi analizler yapmaktadır. Deprem algılama için denetimsiz öğrenme tekniği ile yapılan birçok çalışma bulunmaktadır. Valentine ve Trampert (2012) bir otomatik kodlayıcı ağı kullanan deprem dalga formları için kompakt bir özellik gösterimini önermiştir. Kendi kendini organize eden haritalar (SOM'ler) boyut azaltma ve kümeleme (Kohonen, 2013) için kullanılabilecek gözetimsiz sinir ağ türünün bir başka türüdür. SOM'ler öznitelik seçimi (Köhler ve diğ., 2008), çoklu olayların gruplanması (Esposito ve diğ., 2006) ve dalga benzerliği üzerine temellenen olay gruplama amaçlarıyla sismik dalga formlarına uygulanır. Masiello ve diğ., (2006) depremleri diğer sinyal türlerinden (taş ocağı patlatmaları, sualtı patlatmaları) ayırt etmek için SOMs ve temel bileşen analizi (PCA) içeren birkaç gözetimsiz teknik karşılaştırmıştır. Hiyerarşik kümeleme, tetiklenmiş deprem sürüleri (Bardainne ve diğ., 2006) veya artçı şok dizilerinde (Slinkard ve diğ., 2013) ilişkili olay dalga formlarının ailelerini tanımlamaya dahil keşifsel analizde kullanılan yaygın bir tekniktir. Deprem algılama için gözetimsiz öğrenme tekniklerini kullanan birkaç çalışma bulunmaktadır. Bergen (2018) çalışmasında belirttiği üzere Skoumal ve diğ., (2016) aglomeratif kümelenme kullanarak tekrarlayan deprem sinyalleri algılamasından bahsetmiştir. Denetimsiz örüntü keşfi için veri madenciliği yöntemleri eğitim verilerine dayanmamaktadır ve büyük veri setlerindeki bilinmeyen örüntüleri belirlemektedir. Bu yöntemler sismik sinyal analizi için artan bir ilgiye sahiptir. Örneğin; Aguiar ve Beroza

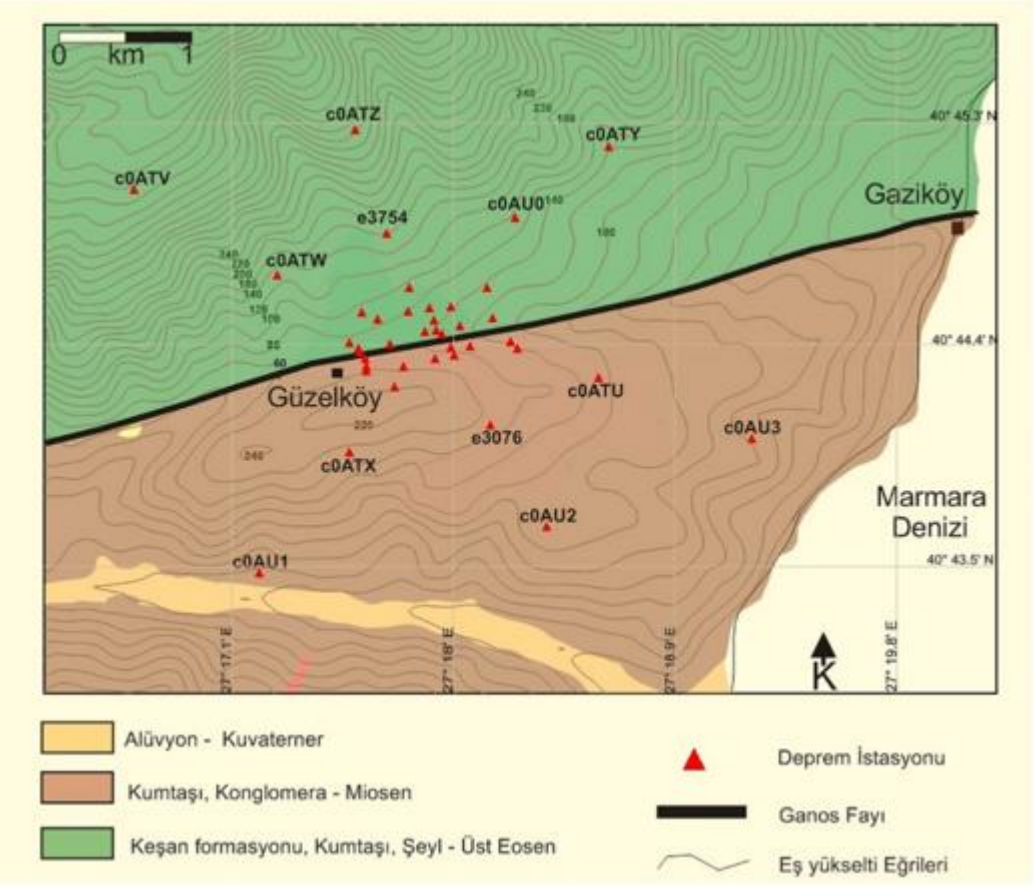
(2014) bağlantı için popüler bir algoritma olan PageRank'ı kullanarak olası düşük frekanslı deprem sinyallerini belirlemiştir.

Bu tez kapsamında da ele alınan deprem algılama dedektörlerinden biri olan FAST (Fingerprint and Similarity Tresholding) (Yoon ve diğ., 2015) sürekli veri setindeki benzer dalga formu çiftlerini belirleyen veri madenciliği tabanlı algoritmalardan biridir. Büyük veri setleri içindeki benzer ses kliplerini belirlemek için tasarlanmış veri madenciliği algoritmalarından ilham almıştır. FAST'in başlangıçtaki ilham kaynağı popüler müzik uygulaması Shazam'dır. FAST algoritması Shazam'a benzer bir algoritma (özellikle ses tanımlamaya odaklı) olan Google araştırmacıları tarafından ses kliplerini eşleştirmek için geliştirilen WavePrint algoritması üzerine kuruludur. WavePrint algoritması, sürekli sismik verilerde benzer depremleri tespit etmeye yönelik olarak FAST'in özelliklerine ve gereksinimlerine göre uyarlanmıştır. FAST deprem ve gürültü örneklerini ayırt edici bir şablon dalga formu gerektirmeden sürekli veride bulanabilecek tüm benzer deprem sinyalleri için kapsamlı bir kör araştırma (blind search) gerçekleştirmektedir. FAST algılama modeli, dalga formu çapraz korelasyonunda olduğu gibi benzer kaynaklara sahip depremlerin benzer dalga formları ürettiği gözlemine dayanmaktadır. Birden çok sismik istasyon ağı üzerinden kaydedilen uzun süreli veri setlerindeki deprem sinyallerini tespit edebilmektedir. FAST, daha öncesinde tespit edilememiş ve sadece küçük depremler üreten deprem kaynaklarını belirleyebilmesi sayesinde seyrek sismik ağlarda yeni depremlerin tespiti için oldukça yararlı olmaktadır. İlk olarak ana ayırt edici özellikler çıkartılarak dalga formunun 'parmak izi' (fingerprint) oluşturulmaktadır, ardından gruplar bir veri tabanı içinde benzer parmak izlerini oluşturmaktadır ve sonunda ayıklanan depremlerin bir listesini üretmektedir. FAST'in temel yeniliği veri sıkıştırma yoluyla son derece verimli karşılaştırmalar yapmasıdır. Bu yöntemle bir haftalık sismik dalga formu verilerini 2 saatten daha kısa sürede ya da otokorelasyondan 140 kat daha hızlı bir şekilde analiz edebilmektedir (Audretsch, 2020).

1.2. TEZ ÇALIŞMASININ AMACI VE KULLANILAN VERİLER

2018 yılında Tübitak-Almanya BMBF ikili iş birliğiyle oluşturulan bir proje kapsamında Ganos Fayı'nın kara segmenti üzerinde toplam 40 adet istasyon oluşan bir deprem izleme ağı (MONGAN-Monitoring Ganos Fault) kurulmuştur. Ağın amacı ulusal gözlem ağlarından elde edilen sonuçlara göre asismik davranış sergileyen GANOS Fayı'nın olası mikrosismik etkinliğini gözlemleyebilmek ve iki malzemeli fay yapısının fay zonu dalgaları analizi ile inceleyebilmektir. Gözlem ağı iki aşamalı çalıştırılmış olup, birinci aşamada

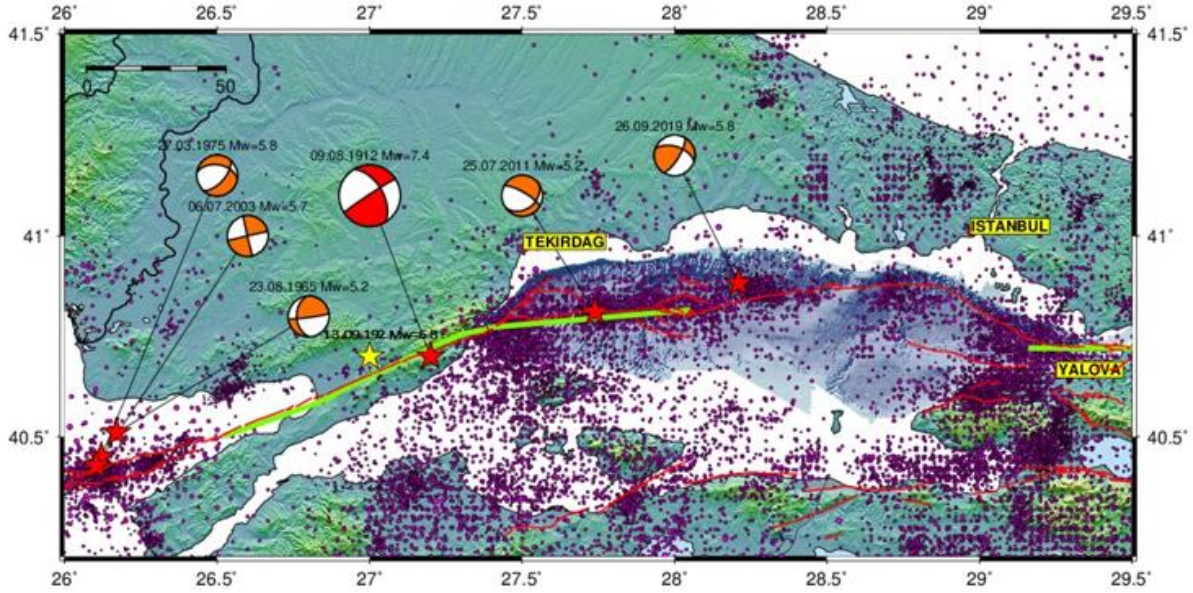
istasyonlar fayın doğu ucunda Güzelköy civarında (MONGAN-1), dar alan içinde 2 yıl süreli çalıştırılmıştır. Bu tez çalışmasında MONGAN-1 ağından alınan kayıtlar kullanılmıştır (Şekil 1.1). Bu lokasyonda istasyon yerleri fayı birkaç noktadan kesecek şekilde, faya dik ve paralel olacak yıldız şeklinde tasarlanmıştır. İstasyonlar arasında en uzak mesafe yaklaşık 4km iken, en yakın mesafe ise 25m civarındadır. İstasyonların bir kısmı doğrudan fay zonu üzerinde kalırken, yarısı daha yaşlı ve sert kaya birimlerden oluşan kuzey blok üzerinde, diğer yarısı ise daha genç ve gevşek birimlerden oluşan güney blok üzerindedir (Yalçınkaya ve diğ., 2020).



Şekil 1.1: MONGAN-1 ağı istasyon dağılımı (üçgenler) ve yüzey jeolojisi. Sadece ağın dış istasyonlarının kodları gösterilmiştir (Yalçınkaya ve diğ., 2020).

Ganos Fayı (GF), Kuzey Anadolu Fay Zonu'nun (KAFZ) batı ucunda, Tekirdağ ile Saros Körfezi arasında yer almaktadır. Ganos Fayı, en son 1912 yılında büyüklükleri 7.4 (9 Ağustos 1912 Mürefte) ve 6.8 (13 Eylül 1912 Saros) olan iki depremle kırılmıştır (Şekil 1.2). Depremlerin Saros Körfezi'nden itibaren karada 45 km ve Marmara Denizi içindeki uzantısıyla birlikte toplam 140 km uzunluğunda çok segmentli bir yüzey faylanması oluşturduğu düşünülmektedir (Rockwell ve diğ., 2001; Altunel ve diğ., 2004; Armijo ve diğ., 2005, Uçarkuş ve diğ., 2011; Aksoy, 2021).

Bu tez kapsamında 2017-2020 tarihleri arasında Ganos Fayı üzerinde çalıştırılan 40 istasyondan oluşan MONGAN-1 deprem izleme ağından toplanan bir aylık deprem verilerinin işlenmesi planlanmıştır. Amacımız bu veriler üzerinde geleneksel deprem ayıklama yöntemlerinden olan STA/LTA oran yöntemi ve FAST algoritmalarını uygulayarak veriler içinde mümkün olan en çok sayıda deprem kaydına ulaşabilmek ve algoritmaların uygun parametrelerini ortaya koyabilmektir. STA/LTA yöntemi günümüzde yaygın olarak kullanılan algoritmalardan biri olan enerji tabanlı bir dedektördür. FAST ise benzer kaynaklara sahip depremlerin benzer dalga formları üretme eğiliminde olduğu gözlemine dayanan, algılama için temel olarak benzerliği kullanan bir dedektördür. Bu nedenle, asıl itibarıyla STA/LTA yöntemine katkı sağlayacak bir ayıklama yöntemi olarak tercih edilebilir. Kullanılan algoritmaların zayıf ve güçlü yönleri araştırılacaktır. Veriler 'SEISAN' ve 'Python-Obspy' gibi ana yazılımlar içinde gömülü olan paket algoritmalar kullanılarak değerlendirilecektir. Elde edilen sonuçların benzer ayıklama işlemleri için örnek oluşturması ve farklı algoritmaların geliştirilmesine ışık tutabilmesi planlanmaktadır.



Şekil 1.2: Çalışma bölgesi ve çevresinin aletsel dönem depremselliği ve ana yapısal unsurlar. Yeşil kalın çizgi 1912 ve 1999 depremleri kırığını temsil eder. Fay boyunca oluşan önemli depremler ve kaynak mekanizma çözümleri gösterilmiştir. Sarı yıldız 13 Eylül 1912 depremi lokasyonunu gösterir (Yalçınkaya ve diğ., 2020).

2. KAVRAMSAL ÇERÇEVE

Otomatik deprem ayıklama, kaydedilen sürekli yer hareketi verilerinde sismik sinyalleri tanımlamak için algoritmaların kullanılmasıdır. Eksiksiz ve doğru deprem katalogları, deprem süreçlerinin incelenmesi ve sismik tehlike analizi için önemli bir yere sahiptir. Binlerce sensör içeren modern sismik ağlar sürekli olarak veri kaydetmektedir. Bu durum mevcut ulaşılabilir veri hacmini artırmakla birlikte sismoloji topluluğunu bu büyük veri setlerini işlemek için gelişmiş algoritmalar ve yoğun hesaplama tekniklerini kullanmaya yönlendirmiştir. Algılama için kullanılan veriler sürekli kaydedilen yer hareketi ölçümleridir. Veriler genelde 20-100 Hz aralığında örnekleme frekanslarında ve düşey veya üç bileşene (düşey, kuzey-güney ve doğu-batı) sahip sismometreler tarafından kaydedilmektedir.

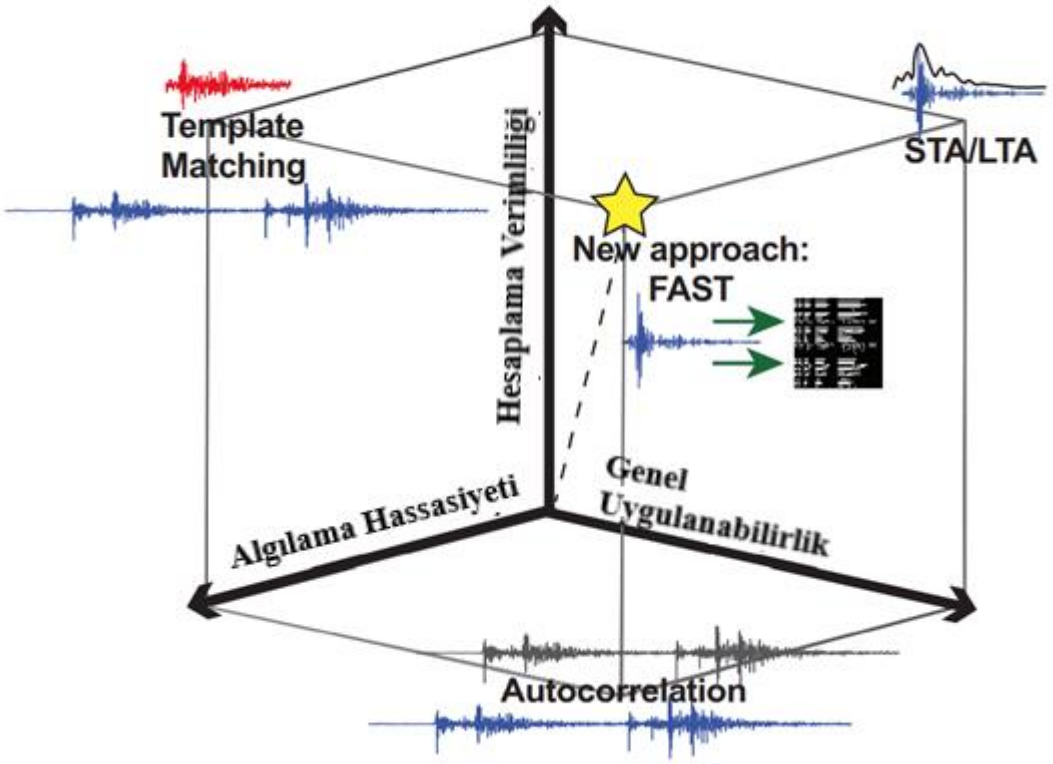
Geleneksel olarak bir deprem kısa zaman ortalama (STA)/uzun zaman ortalama (LTA) gibi enerji dedektörü kullanılarak bir istasyonda tespit edilebilmektedir. STA/LTA, kısa zaman penceresindeki STA enerjisini, uzun zaman penceresindeki (LTA) enerjisine oranını hesaplamaktadır. STA/LTA oranı verilen eşiği aştığında bir algılama bildirilmektedir. Daha sonrasında bir ilişkilendirme algoritması ağ üzerindeki çoklu istasyonlardaki algılamaların bir sismik kaynakla tutarlı olup olmadığını belirlemektedir. Örneğin en az dört istasyon sismik olay tespit edilirse, çözüm için saklanmakta ve sonrasında depremlerin konumu, oluş zamanı ve büyüklükleri bir veri tabanı olan deprem kataloglarına dahil edilmektedir. STA/LTA dedektörleri keskin varışlı depremleri (P ve S varışlarındaki yüksek sinyal/gürültü oranı) başarılı şekilde tanımlayabilirken, düşük sinyal/gürültü oranlarında, yumuşak (emergent) dalga fazı başlangıçlarında, örtüşen olaylarda, kültürel gürültü, seyrek istasyon aralığı gibi değişen durumlarda depremleri algılayamaz veya yanlış tetiklenmeler üretebilir. Bu açıdan STA/LTA dedektörleri nispeten düşük algılama hassasiyetine sahiptir (Şekil 2.1). Bu nedenle düşük magnitüdlü olaylar deprem kataloglarında genelde eksiktir (Yoon ve diğ., 2015).

Dalga formu benzerliğine dayalı deprem dedektörleri (şablon eşleştirme) çok geniş veri kümelerine başarıyla uygulanmıştır. Ancak bu yöntemler bilinen kaynaklara ait benzer dalga formuna sahip olayları tespit etmek ile sınırlıdır (Şekil 2.1). Otokorelasyon dedektörü (Brown ve diğ., 2008) deprem ayıklamada birçok açıdan daha başarılıdır. Ancak artan veri yüküyle hesaplama sürelerindeki anormal artışalar nedeniyle nispeten küçük veri setlerinde kullanımı sınırlıdır. Son zamanlarda FAST (Yoon ve diğ., 2015) ve Skoumal ve diğ., (2016) Tekrarlanan

Sinyal Dedektörü (RSD) dalga formu karakteristiği veya dalga formu özellikleri hakkında daha önceden bilgi sahibi olmadan dalga formu benzerliğine dayalı bu yöntemlerin sınırlamalarından bazılarına değinmektedir. Bu tez kapsamında da ele alınan diğer deprem algılama dedektörlerinden biri olan FAST (Yoon ve diğ., 2015) sürekli veri setindeki benzer dalga formu çiftlerini belirleyen veri madenciliği tabanlı algoritmalardan biridir. FAST benzer kaynaklara sahip depremlerin benzer dalga formları üretme eğiliminde olduğu gözlemine dayanan algılama için temel olarak benzerliği kullanan bir dedektördür.

Yüksek benzerliğe sahip herhangi bir dalga formu çiftini aday depremler olarak kabul ederek daha önceden bilinmeyen kaynaklı olayları belirleyebilir. Ancak bu, FAST'i yanlış algılamalara karşı da duyarlı hale getirir. Tüm benzer dalga formları çiftleri depremlere atfedilemez. Benzer veya tekrarlayan dalga formları kalıcı yerel gürültü kaynaklarına da atfedilebilir. FAST daha büyük veri setlerinde kullanıldığında geri döndürülen yanlış algılamaların sayılarının sınırlandırılması önemli bir noktadır. Kullanılan dedektörün hassasiyetinin düşük olması yapılan algılamanın çıktısından faydalı bilgiler çıkarılmasını zorlaştırmaktadır. Herhangi bir dedektörde olduğu gibi, yanlış algılamalar, detection threshold (algılama eşiği) yükseltilerek bastırılabilir, fakat zayıf sinyallere karşı performansına zarar vermesine ve algılama hassasiyetini düşürme etkisine sahiptir. LSH (Locality Sensitive Hashing) tabanlı benzerlik araştırmasının doğası gereği daha yüksek bir yanlış algılama oranı çıktıyı yorumlama ve analiz etme açısından bir zorluk teşkil etmez. Fakat aynı zamanda FAST benzerlik arama adımı boyunca daha yavaş çalışmasına neden olmaktadır.

FAST'ın amacı STA/LTA gibi standart yöntemler ile tespit edilmeyen zayıf deprem sinyallerini tespit etmektir. Bu yüzden FAST daha büyük veri kümelerine ölçeklendiğinden yüksek algılamayı sürdürmek kritik öneme sahiptir. Ancak LSH tabanlı benzerlik araması için yüksek duyarlılığı korumak bir problemdir.



Şekil 2.1: Deprem algılama yöntemlerinin üç nitel metrik açısından karşılaştırması (Yoon ve diğ. 2015): Algılama hassasiyeti (detection sensitivity), genel uygulanabilirlik (general applicability), hesaplama verimliliği (computational efficiency). STA/LTA yöntemi bilinmeyen kaynaklı depremleri bulma ve gerçek zamanlı algılama nedeniyle genel uygulanabilirlik ve hesaplama verimliliği açısından yüksek puan almaktadır. Ancak düşük S/N oranına sahip sismik sinyalleri kaçırması nedeniyle algılama hassasiyeti düşüktür. Şablon eşleştirme (templete matching) düşük S/N oranlarında depremleri bulabildiğinden, algılama duyarlılığında ve hesaplama verimliliğinde yüksek puanlara sahiptir. Ancak önceden belirlenecek olan (şablon dalga formu) gerektiğinden genel uygulanabilirlik puanı düşüktür. Otokorelasyon yüksek algılama hassasiyetine ve bilinmeyen benzer depremleri bulabilmesi nedeniyle genel uygulanabilirliği yüksektir. Ancak sürekli veri kümesinin boyutuyla düşen hesaplama verimliliğine sahiptir. FAST her 3 metriğe göre daha iyi performans gösterir (çapraz korelasyona dayalı algılama duyarlılığı, genel uygulanabilirliği ve yüksek hesaplama verimliliği) (Bergen, 2018'den değiştirilmiştir.).

3. YÖNTEM

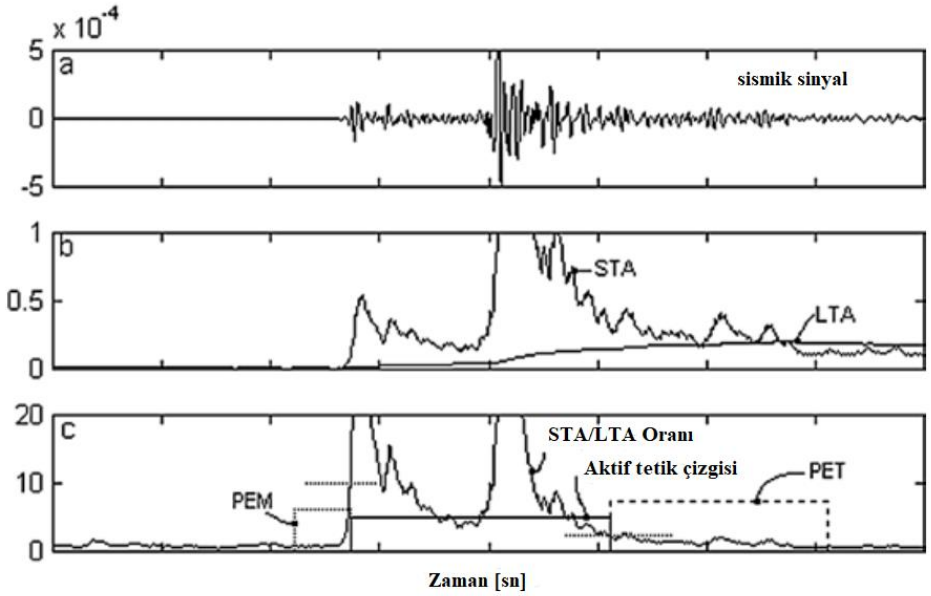
3.1 STA/LTA YÖNTEMİ

Günümüzde yaygın olarak kullanılan algoritmalardan biri olan STA/LTA yöntemi enerji tabanlı bir dedektördür. Enerji tabanlı dedektörler dalga varışlarıyla ilişkili sinyal enerjisindeki artışa bağlı olarak sismik dalganın başlangıcını belirlemek için kullanılan etkili olay dedektörleridir. Enerji dedektörleri sinyal hakkında temel bilgileri vermektedir ve dalga formunun karakteristiğinden faydalanmamaktadır. Yaklaşımın basitliği enerji dedektörlerini hesaplama açısından verimli kılmaktadır. Bu yöntemde ardışık iki hareketli penceredeki sismik sinyalin mutlak genliklerinin ortalama değerleri hesaplanmaktadır. STA (short time window) sismik olaylar için hassasken, LTA (long time window) sahadaki sismik gürültünün zamansal genliği hakkında bilgi sağlamaktadır. Her ikisi arasındaki oran önceden belirlenen bir eşik seviyesini aştığında, sismik olay bildirilmekte ve veriler dosyaya kaydedilmeye başlamaktadır. STA/LTA iki kritik parametresi vardır: Kısa vadeli pencere uzunluğu (STA) ve uzun vadeli pencere uzunluğu (LTA). STA/LTA daha önceki verilere dayanmadığından, bu da onu istasyonun yeni kurulduğu ve önceki verilerin kaydedilmediği durumlar için faydalı hale getirmektedir. Ayrıca kayan pencere hesaplaması sabittir, yani dalga formu uzunluğuna göre STA/LTA doğrusal çalışma süresine sahip olacaktır. STA/LTA herhangi bir önkoşul olmaması açısından önemlidir ve benzersiz özelliklere sahip sinyalleri tespit edebilmektedir. Ancak etkili olması yüksek S/N oranına bağlıdır.

3.1.1 STA/LTA Çalışma Prensibi

STA/LTA algoritması şu şekilde çalışmaktadır: İlk olarak gelen sinyalin her bir veri örneğinin mutlak genliği hesaplanmaktadır. Sonrasında her iki pencerenin mutlak genliklerinin ortalaması hesaplanmaktadır. Bir sonraki adımda ise hesaplanan her iki değerin STA/LTA oranı hesaplanmaktadır. Bu oran sürekli olarak önceden seçilmiş olan tetik eşik seviyesi (tigger threshold level) ile karşılaştırılır. STA/LTA oranı, bu tetik eşik seviyesi değerini aşması durumunda tetikleme bildirir ve sismik sinyali kaydetmeye başlar. Kayıt, önceden belirlenmiş olan tetiklenmenin son bulacağı eşik seviyesi (dettriger threshold level) değerinin altına düştüğünde ise sonlanmaktadır. Bu yöntemde P varışı istasyona ulaştığında sinyalin hem genliğinde hem de frekansında bir değişimi hesaba katan karakteristik bir fonksiyon

öngörülmektedir. Tanımlanan bu karakteristik fonksiyon (CF) kullanılarak kısa dönemli ve uzun dönemli iki ardışık kayan pencere içindeki bir sismik sinyalin mutlak genliğine ilişkin ortalama değerlerin oranları hesaplanmaktadır. CF, sinyalin karesi, mutlak değeri veya zamanın türevi olabilmektedir. Şekil 3.1'de STA/LTA tetikleme hesaplamalarının değişkenleri ve işlevi ile ilgili örnek verilmiştir.



Şekil 3.1: STA/LTA tetikleme hesaplamalarının değişkenleri ve işlevi. a) Sürekli bir sinyal (filtrelenmiş) b) STA, LTA pencerelerinin mutlak ortalamasını gösterir c) STA/LTA oranını gösterir. Ek olarak tetik aktif durum çizgisi (trigger active state) (düz çizgi dikdörtgen ile gösterilmiş), olay sonrası süre (post event time, PET), olay öncesi süre (pre event time, PEM) gösterilmiştir. (Trnkoczy, A. (2009)'dan değiştirilmiştir.).

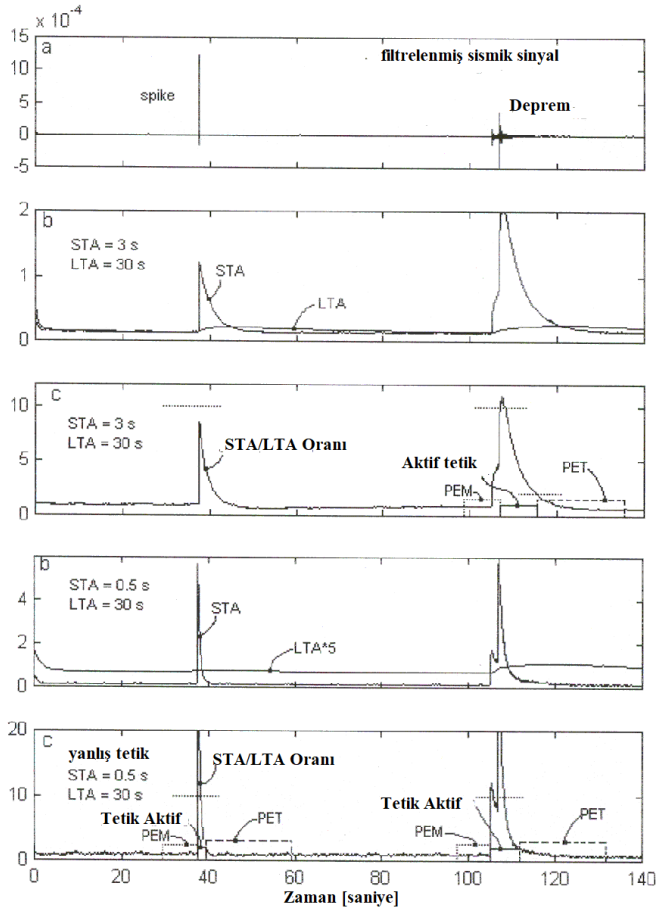
Şekil 3.1'de verilen örnekte tetik eşik seviyesi (trigger threshold level) 10 olarak ayarlanmıştır. Tetiklenmenin sona ereceği eşik seviyesi (detrigger threshold level) 2 olarak ayarlanmıştır. STA/LTA oranı 10'u aştığında tetikleyici aktif hale gelir. Oran 2'nin altına düştüğünde tetiklenme sona ermektedir. Ayrıca tetik aktif süresi boyunca elde edilen verilere ek olarak, sismik ağlar ve sismik kayıt cihazları tetiklenme öncesi (PEM) ve sonrası (PET) olay (event) dosyasına veri eklemektedir.

3.1.2. STA/LTA Parametrelerin Seçimi

STA/LTA tetikleme parametresi ve ilgili parametrelerin ayarları, uygulamanın amacına, sahadaki sismik gürültünün durumuna, belirli bir konumundaki sismik sinyallerin özelliklerine ve kullanılan sensör tiplerine bağlıdır (Trnkoczy, 2009).

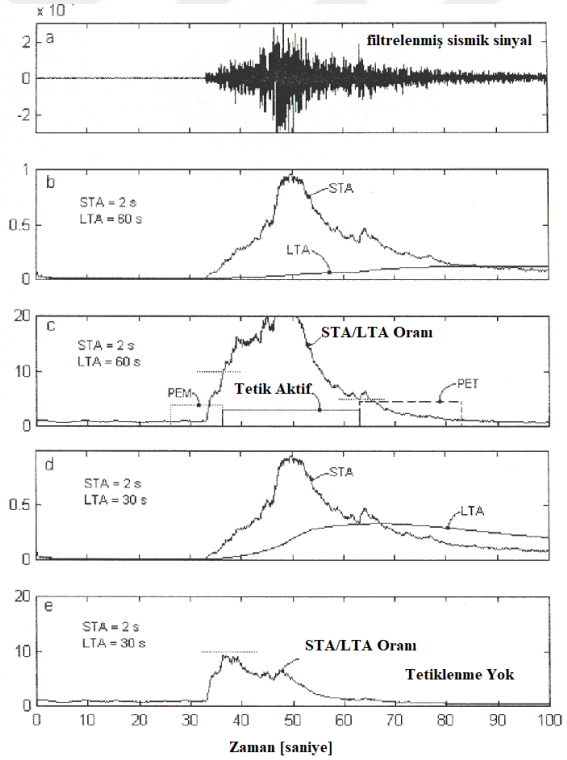
Kısa Zaman Pencere Ortalama (STA) Süresinin Seçimi; STA penceresi bir sismik sinyalin ya da zarfının anlık değerini ölçmektedir. Genel olarak STA süresi tipik olarak beklenen bir

sismik sürenin birkaç periyodundan daha uzun olmalıdır. Bir dereceye kadar STA, bir sinyal filtresi işlevi görmektedir. STA çok kısaysa, sismik sinyalin ortalaması düzgün çalışmayacaktır. Seçilen STA süresi ne kadar kısa olursa, tetikleyicinin kısa süreli yerel depremlere duyarlılığı, uzun süreli ve daha düşük frekanslı olan uzak depremlere kıyasla o kadar yüksek olacaktır. Ayrıca STA pencere süresini azaltma tetiklemeyi insan yapımı sismik gürültüye karşı daha hassas hale getirebilmektedir. Bu da sismik gürültülerin tetiklediği yanlış kayıtlara sebep olabilmektedir. Genel olarak bölgesel depremler için tipik bir STA süresi 1 ile 2 saniye arasında iken yerel depremler için ise 0.3 ile 0.5 arasında değerler seçilmektedir.

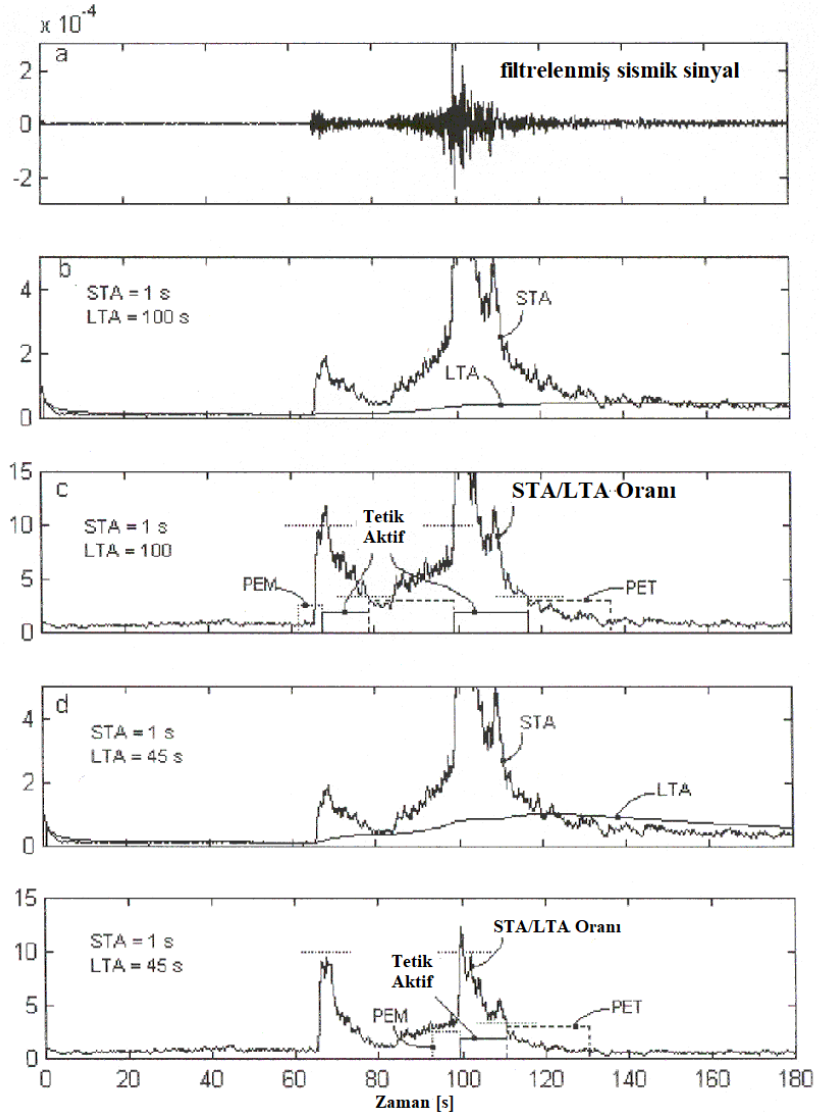


Şekil 3.2: Sismik sinyaldeki 'spike' ve kısa yerel olaylar için tetiklenme hassasiyetinin STA süresinin etkisi. a) Sol tarafta iğnecik şeklinde kayıt görülürken sağ tarafta yerel bir deprem kaydı gösterilmiştir. b) STA, LTA değerleri gösterilmiştir c) STA/LTA oranı ile birlikte olay öncesi süre (PEM), olay sonrası süre (PET) ve aktif durum çizgisi gösterilmiştir. Burada STA/LTA tetik eşik seviyesi 10, tetiklenmeyeceği eşik seviyesi 2 olarak seçilmiştir. 3 sn'lik STA süresi deprem tetiklemiş ancak çok daha büyük genlikli iğnecikleri tetiklememiştir. Böylelikle 3 sn'lik STA süresinde herhangi bir yanlış tetikleme olmamıştır. Alttaki b ve c grafikleri aynı değişkenleri göstermektedir. Ancak burada STA süresi 0.5 sn seçilmiştir. Burada görüldüğü üzere iğnecik tetiklenerek yanlış bir tetiklemeye neden olmuştur (Trnkoczy, 2009'dan değiştirilmiştir.).

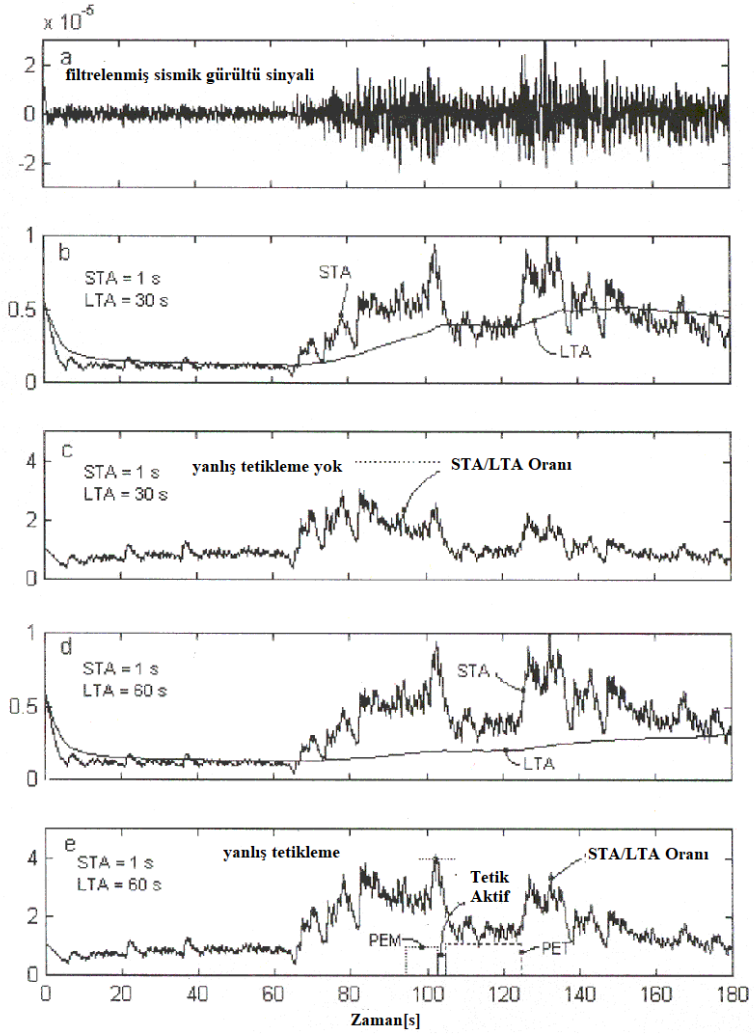
Uzun Zaman Pencere Ortalaması (LTA) Süresinin Seçimi; LTA sismik gürültüdeki ortalama genliği ölçmektedir. Tipik düzensiz sismik gürültü dalgalanmalarının birkaç periyodlarından daha uzun süreli olmalıdır. LTA pencere süresini değiştirerek, kayıt yaklaşık episantr uzaklığı 1500-2000 km mesafe arasındaki Pn dalgası aralığındaki bölgesel olaylara daha çok ya da daha az hassas hale getirebilmektedir. Kısa bir LTA süresi, LTA değerinin, ortaya çıkan sismik dalgaların yavaşça artan genliğinin az ya da çok ayarlanmasına izin vermektedir. Dolayısıyla STA/LTA oranı, artan STA'ya (oran artışının payı ve paydası) rağmen düşük kalmaktadır. Böyle depremlere karşı tetiklenme hassasiyeti etkili bir şekilde azaltmaktadır. Tersi durumda, uzun bir LTA pencere süresi kullanıldığında, ortaya karşı çıkan depremlere karşı tetiklenme hassasiyeti artmaktadır. Çünkü LTA değeri ortaya çıkan sismik sinyalden çok hızlı etkilenmemektedir ve Sg/Lg dalgalarının kaydı tetiklemesine izin vermektedir. Şekil 3.3, 3.4 ve 3.5'te farklı sismik kayıtlarda farklı sürelerde seçilen LTA değerlerinin tepkileri grafiklerle açıklanmıştır.



Şekil 3.3: Yumuşak sismik sinyalli deprem için tetikleme algoritma hassasiyetine LTA süresinin etkisi. a) P dalgasının ortaya çıktığı bir deprem gösterilmiştir. b)LTA değeri 60 s ve STA 2 s olarak alınmıştır. c)LTA değeri grafikte görüldüğü üzere hızlı bir şekilde değişmemektedir. STA/LTA oranı, STA/LTA tetik eşik seviyesini (trigger threshold level) aşarak normal bir kayıtla sonuçlanmasına izin verdi. d) ve e) grafiklerin de aynı durum 30 sn'lik daha kısa bir LTA süresi seçilerek uygulanmıştır. d grafiğinde görüldüğü üzere LTA değeri uygulamanın ilk başında hızlı arttığından STA/LTA oranının artmasına izin vermemekte ve dolayısıyla STA/LTA oranı, tetik eşik seviyesini (trigger threshold level) aşamadığından tetiklenme meydana gelmemekte ve deprem kaçırılmaktadır (Trnkoczy, 2009'dan değiştirilmiştir.).



Şekil 3.4: Zayıf P dalgasını içeren deprem için tetiklenme algoritma hassasiyetine LTA süresinin etkisi. a) P dalgasından daha büyük dalgaların olduğu bir kayıt verilmiştir. b) STA süresi 1 sn ve LTA süresi 100 sn olarak seçilmiştir. c) görüldüğü üzere seçilen parametrelerin P ve S dalga paketlerini tetiklediği görülmektedir. d) d'de aynı durum için 45 s'lik daha kısa bir LTA süresi seçilmiştir. Grafik e'de görüldüğü üzere S dalgası zar zor tetiklenebilirken, P dalgası hiç tetiklenmemiştir. Bu nedenle kaydedilen veri dosyası ise çok kısa olmaktadır. Ayrıca kaydedilen veri dosyasında P dalgası ve öncesindeki sismik gürültü hakkında bilgi eksik kalmaktadır. Bundan daha küçük depremler kayıt altına alınamamaktadır (Trnkoczy, 2009'dan değiştirilmiştir.).



Şekil 3.5: Sismik gürültü durumunda yanlış tetiklenmeye LTA süresinin etkisi. a)kaydın ortasına doğru artan sismik gürültü görülmektedir. Genliklerin değişimi ani değil yaklaşık 20-30 sn sürmektedir. b ve c 'de LTA süresi 30 sn olarak seçilmiştir. LTA değerinin aşağı yukarı sismik gürültüyü takip ettiği görülmektedir. STA/LTA oranı, STA/LTA tetikleyicisinin altında kalmakta ve önemli ölçüde artan gürültüye rağmen yanlış tetiklenmeye izin vermemektedir. d ve e'de LTA süresi 60 s olarak seçilmiştir. LTA hızlı değişmediğinden gürültü artışı sırasında daha yüksek bir STA/LTA oranına izin verir. Sonuç olarak yanlış bir tetiklenmeye neden olur ve kayıtçının hafızasında gereksiz yer tutmasına neden olur (Trnkoczy, 2009'dan değiştirilmiştir.).

STA/LTA Tetik Eşik Seviyesi (Trigger Threshold Level) Seçimi; STA/LTA tetik eşik seviyesi, büyük ölçüde hangi olayların kaydedilip kaydedilmeyeceğini belirlemektedir. Tetik eşik seviyesi çok yüksek değerlere ayarlandığında, çok fazla deprem kaydedilemeyecek ancak daha az yanlış tetiklenme ile sonuçlanacaktır. Tetik eşik seviyesi ne kadar düşük seviye seçilirse, sismik istasyon çok daha hassas olacak ve çok daha fazla olay kaydedilecektir. Ancak bununla birlikte daha sık yanlış tetiklenmeler veri belleğini işgal edecektir. Sadece genlik değil aynı zamanda sismik gürültü türü de optimum STA/LTA tetik eşik seviyesi ayarını etkilemektedir. Ayrıca STA/LTA tetik eşik seviyesi bölgedeki sismik gürültü koşullarına ve

yanlış tetiklenen kayıtların toleransına bağlıdır. İstatiksel olarak sabit bir sismik gürültü (daha az düzensiz dalgalanmalarla), daha düşük bir STA/LTA tetik eşik seviyesine izin verirken; sismik gürültünün tamamen düzensiz davranışı daha yüksek değerler istemektedir (Trnkoczy, 2009).

STA/LTA Tetiklenmeyeceği Eşik Seviyesi (Detrigger Threshold Level) Seçimi; STA/LTA tetiklenmeyeceği eşik seviyesi, veri kaydının sonlandırılmasını belirlemektedir. Genel olarak sismik alan ne kadar gürültülü olursa çok uzun veya sürekli kayıtları önlemek için daha yüksek STA/LTA tetiklenmeyeceği eşik seviyesi kullanılmalıdır. Bu tehlike sadece insan yapımı sismik gürültüyle yoğun bir şekilde kirlenen alanlarda yüksektir. STA/LTA tetiklenmeyeceği eşik seviyesinin başlangıç değeri sismik olarak sessiz ve zayıf hareket uygulamalarında 2- 3'tür. Daha gürültülü alanlar için daha yüksek değerler ayarlanmalıdır (Trnkoczy, 2009).

Tetik Filtrelerinin Seçimi; Sismik kayıt cihazları ve ağlar genellikle bant- geçişli tetik filtrelere sahiptir. Tetikleyici algoritma hesaplamalarından önce gelen sismik sinyalleri sürekli olarak filtrelerler. Bu filtrelerin seçimi, STA/LTA tetikleme algoritmasının (ve genlik eşiği tetikleme algoritmasının) düzgün çalışması için önemlidir. Tüm aktif sismik sensörler STA/LTA oranı hesaplamasını bozan bir miktar DC ofset voltajına (sıfır çizgisinden kayma) sahiptir. Filtreler ise DC bileşenini gelen sismik sinyallerden uzaklaştırırlar. DC bileşeni sismik gürültü genliğinden yüksekse, sinyalin mutlak değerinin hesaplanması anlamsız hale gelir. Bu, STA/LTA tetikleme algoritmasının arızalanmasına ve zayıf sismik olaylar için tetik hassasiyetinin ciddi şekilde azalmasına neden olur. Frekans bandı geçişleri, birinin kaydetmek istediği sismik olayların baskın frekanslarına karşılık gelen frekanslara öncelik verebilir ve stop- bant belirli bir bölgedeki en dikkat dağıtıcı sismik gürültünün baskın frekanslarını azaltabilir. Bant geçişli tetik filtre genellikle beklenen sismik olayların maksimum enerjisinin frekanslarını karşılamalıdır. Aynı zamanda bölgedeki tipik sismik gürültünün pik frekans bileşenleri ile çakışmayan bir bant-geçişine sahip olmalıdır. Böylece olay-tetik/yanlış-tetik oranı sonucunda önemli bir iyileşme olur. Kısacası, sismik gürültünün tepe genlikleri ile ilgilenilen olayların baskın frekansları çakışırsa, tetik filtrenin verimsiz hale geldiği anlaşılabilir (Trnkoczy, 2009).

3.1.3. STA/LTA Yönteminde Kullanılan "CONDET" Programı

Bu tez çalışmasında STA/LTA yöntemi SEISAN içinde yer alan CONDET programı ile çalıştırılmıştır. CONDET programı, bir SEISAN sürekli veri tabanında veya bir BUD veya SeisComp arşivinde düzenlenen veriler üzerinde çalışan bir algılama programıdır. Gerçek

zamanlı işleme sistemlerine benzer bir algılama işlemi gerçekleştirir. Program iki adımda çalışır, ilk önce tek bir kanalda bir dedektör çalıştırmakta ve ikinci aşamada minimum istasyon sayısından daha fazla olan olayları tespit etmektedir. İsteğe bağlı olarak, algılanan olaylar ayıklanabilir, kaydedilebilir ve bir veri tabanına kopyalanabilir. Programda üç yerleşik algılama algoritması bulunmaktadır: 1) standart STA/LTA, 2) Carl Johnson's dedektörü, 3) korelasyon. Program, bir algılama listesi (istasyon adı, bileşen kodu, tetikleme süresi ve tetikleme süresi veren **condet.out** dosyası) ve aynı zamanda ilgili olay verilerini sürekli verilerden ayıklamak için kullanılabilecek bir toplu iş dosyası (file extract.batch) yazar. Herhangi bir komut satırı seçeneği olmadan başlatıldığında, program STATION parametresi tarafından verilen tüm istasyonlarda/veri tabanlarında çalışır. Çıktı dosyası tüm istasyonlardan algılamalara sahiptir ve "**extract.batch**" dosyası tüm algılamalar için ayıklama komutlarına sahiptir. Tüm bunlar yalnızca bir istasyon mevcutsa gereklidir. Birden çok istasyon için minimum istasyon sayısından daha fazlasının tetiklendiği zamanları aramak mümkündür. Bunun için programı '-net' komut satırı ile başlatılarak yapılır. Bu modda, ilk çalıştırmadan "**condet.out**" çıktı dosyası kullanılır ve "**extract.batch**" dosyasının üzerine yazılır. Ayıklama komut dosyası (extract script) artık ağ tarafından algılanan olaylar için veri almak üzere kullanılabilir. Programda kullanılan giriş parametreleri "**condet.par**" dosyasında verilmektedir. Bu dosya içinde tanımlanan parametreler (Şekil 3.6) kısaca şu şekilde açıklanabilir:

İSTASYON: Verilen sürekli veri tabanının ismi, istasyon ve bileşen kodu. Eğer bir arşiv varsa veri tabanı adı kullanılmaz.

WAVEOUT: Orijinal veri ve tetik kanallarının olduğu dalga formu dosyalarını yazmak için 1'e ayarlanmaktadır.

EXTRACT DURATION: "extract.batch" dosyasında kullanılan saniye cinsinden kesilen pencerenin uzunluğu.

PRE-EVENT TIME: Saniye cinsinden, algılama süresinden önce ayıklamanın başlatılma süresi.

INTERVAL: Bir zaman da okunan veri segmentinin uzunluğu.

DET ALGORITHM: Algılama için kullanılacak algoritmanın seçilmesi. STA/LTA için STA, korelasyon için COR ve Carl Johnson's algoritması için CAR seçeneği seçilmektedir.

MIN TRIG DURATİON (Minimum Tetik Süresi): Tetik düzeyinin aşılması gereken minimum süresi.

MIN TRIG İNTERVAL: Saniye cinsinden verilecek olan bu süre içinde yalnızca bir algılamaya izin vermesi.

FİLTER LOW: En düşük bant-geçiş filtresi.

FİLTER HİGH: En yüksek bant-geçiş filtresi.

STA LENGTH (STA UZUNLUĞU): STA pencere uzunluğu, saniye cinsinden.

LTA LENGTH (LTA UZUNLUĞU): LTA pencere uzunluğu, saniye cinsinde.

TRİGGER RATİO: Tetik için gereken STA/LTA oranı.

DETTRİGER RATİO: Tetiklenmenin son bulması istenilen oran.

Ağ algılama parametreleri:

NET MIN DET: Verilen zaman penceresi ile farklı istasyonlardan gerek minimum istasyon sayısı.

NET WİNDOW SEC: Ağ algılaması için saniye cinsinden zaman penceresi.

NET MAX DELT SEC: Kullanıcının ardışık iki istasyonda varışlar arasında izin verilen maksimum süreyi belirtmesine izin verir.

EXTRACT DURATION: Veri kesme süresi, saniye cinsinden.

NET MIN RATIO: Korunması gerek minimum STA/LTA oranı.

```
#
# condet.par: condet input parameter file, comments can be added to this file,
#             but the comments must not match a KEYWORD
#
#  this exampel file is set up to run with the archive test data form the
#  test data set
#

KEYWORD.............Comments.............Par 1.....Par 2

STATION                                          c0ATY SH Z
STATION                                          c0AU0 SH Z
STATION                                          e3099 SH Z
STATION                                          c0ATV SH Z
STATION                                          c0ATW SH Z
STATION                                          c0ATZ SH Z
STATION                                          c0AU1 SH Z
STATION                                          c0AU2 SH Z
STATION                                          c0AU3 SH Z
STATION                                          e3754 SH Z

BASE TYPE                                 arc

START DATE          yyyymmddhhmmss        20190114000000
STOP DATE           yyyymmddhhmmss        20190114235959
WAVEOUT                                   0.
EXTRACT DURATION                          120.
PRE EVENT TIME                            30.
INTERVAL            length of data        60.
                    segments read (min)

DET ALGORITHM       STA, COR or CAR       STA
STA LENGTH          in seconds            0.3
LTA LENGTH          in seconds            30.
MIN TRIG DURATION   in seconds            1.
MIN TRIG INTERVAL                         20.
FILTER LOW          0. for no filter      5.0
FILTER HIGH         0. for no filter      15.0

#
# STALTA settings
#
TRIGGER RATIO                             3.
DETRIGGER RATIO                           2.
FREEZE LTA          1.=to keep LTA        0.
                    when trigger
#
# CARL settings
#
CARL RATIO                                1.6
CARL QUIET                                3.0

#
# COR settings
#
CORRELATION MIN                           0.6
MASTER WAVEFORM                           2019-01-02-1834-00S.c0ATY_001SH_Z
#
# network detection
#
NET MIN DET                               5.
NET WINDOW SEC                            60.
EXTRACT DURATION                          200.
NET MAXDELT SEC                           3.
NET MIN RATIO                             5.
```

Şekil 3.6: “CONDET” programı giriş parametre dosyası “condet.par”.

3.2 FAST (Fingerprint and Similarity Thresholding)

Bölgesel veya küresel sismik ağlar tarafından oluşturulan deprem kataloglarında tipik olarak orta ve büyük magnitütlü (>M4-5) olaylar tespit edilebilirken daha küçük magnitütlü olaylar için eksik olduğu bilinmektedir. Bu küçük olaylar hissedilemeyecek ya da bir yapısal hasara neden olamayacak kadar çok küçük olmasına karşın deprem süreçleri ve sismik tehlike hakkında önemli bilgiler içerebilmektedir. Daha eksiksiz kataloglar ile aktif bir sismik bölgedeki bir fay boyunca meydana gelen sismik aktivitenin daha iyi anlaşılması sağlanmış olacaktır.

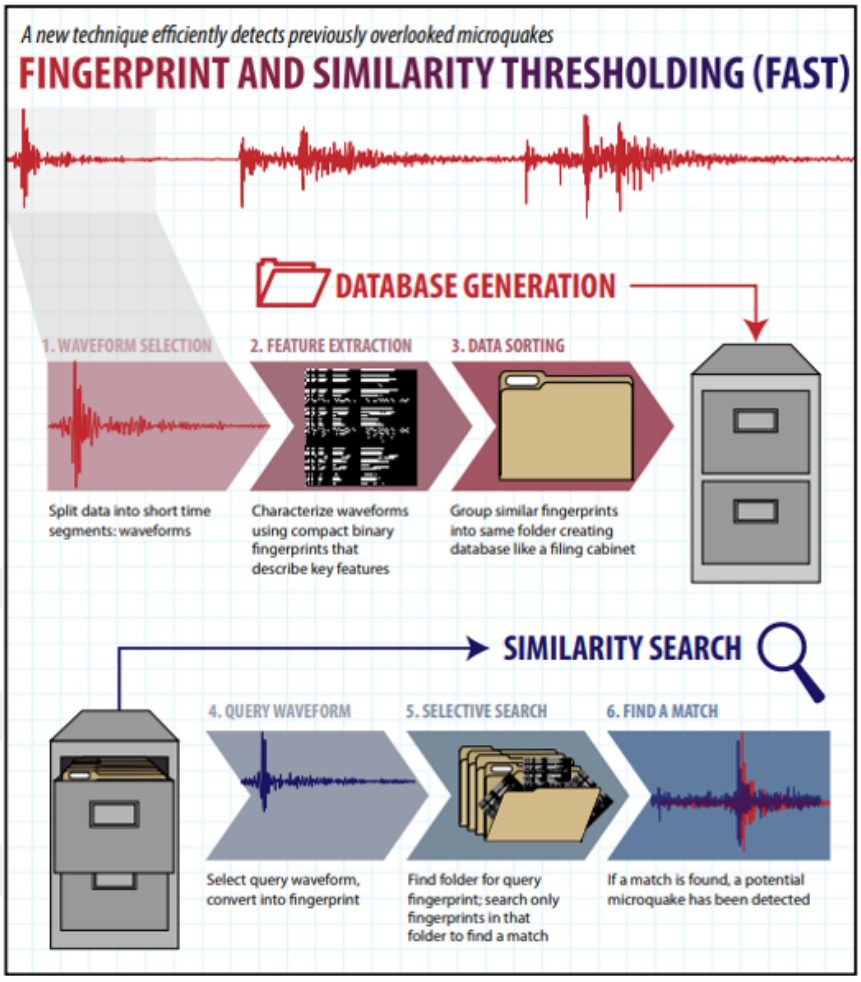
Deprem algılamada ilgilenilen depremlerin seyrek meydana gelmesi ve sinyallerinin kısa süreli olması gibi birtakım problemlerle karşılaşılmaktadır. Bu nedenle deprem tespitinde, çoğu yerel ve kalıcı gürültü kaynaklar gibi arka plan sinyaller içeren verilerin proses edilmesini gerektirmektedir. Bir deprem algılama sistemi yanlış alarm oranını kontrol ederken, küçük depremlerdeki zayıf sinyalleri tespit edebilmelidir. Aksi takdirde fazla sayıda yanlış algılama da gerçek olaylar tespit edilemeyebilir. Günümüzde kullanılan birçok algılama dedektörleri bulunmaktadır. Dalga formu benzerliğine dayalı deprem dedektörleri çeşitli veri setlerine başarıyla uygulanmıştır. Ancak bu yöntemler bilinen kaynaklı benzer dalga formuna sahip olayları algılamak ile sınırlıdır. Otokorelasyon dedektörü (Brown ve diğ., 2008) daha geneldir ancak; zayıf ölçekleme nedeniyle nispeten küçük veri setleri üzerinde kullanılmaktadır. FAST (Yoon ve diğ., 2015) ve Repeating Signal Dedector (RSD) (Skoumal ve diğ., 2016) gibi son yöntemler, şablon dalga formları (template waveforms) veya dalga formu karakteristiği hakkında önceden bilgi sahibi olmadan dalga formu benzerliğine dayalı algılamaya imkân tanımaktadır.

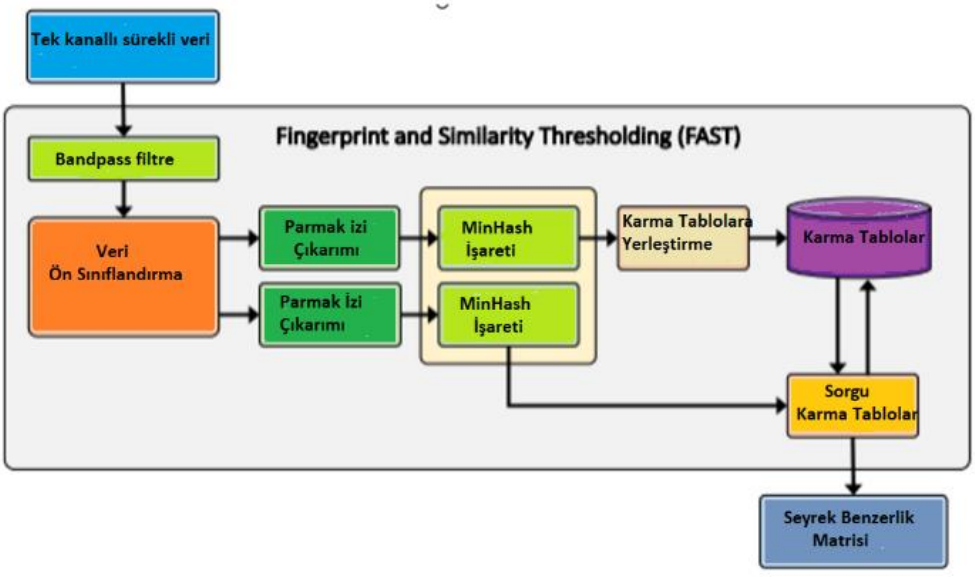
Bu tez kapsamında kullanılan Fingerprint and Similarity Thresholding (FAST) (Yoon ve diğ., 2015) algoritması veri madenciliği yaklaşımını kullanan ve dalga formu benzerliğine dayanan bir deprem algılama dedektörüdür. Bu yöntem, bilgisayar görme tekniklerini ve benzer ses kliplerini eşleştirmek için büyük ölçekli veri işleme yöntemlerinin kombinasyonu olan waveprint ses parmak izi algoritması üzerine kuruludur. Deprem ve gürültü örneklerini ayırt edici bir şablon dalga formu gerektirmeden sürekli veride bulunabilecek tüm benzer deprem sinyalleri için kapsamlı bir arama gerçekleştirmektedir.

FAST algoritması ilk olarak Yoon ve diğ., (2015) tarafından tek kanallı sürekli sismik verideki benzer sinyalleri belirlemek amacıyla kullanılmıştır. Tek kanallı FAST algoritması iki temel adımdan oluşmaktadır (Şekil 3.7): Parmak izi Çıkarımı (Fingerprint Extraction) ve Benzerlik Arama (Similarity Search). FAST, ilk adımda dalga formlarının temel ayırt edici

özelliklerini ayıklayarak “dalga formu parmak izi” olarak da adlandırılan kompakt parmak izleri oluşturmaktadır. Daha sonrasında tüm parmak izleri LSH (Locality Sensitive Hashing) fonksiyonları kullanılarak bir veri tabanına eklenmektedir. Veri tabanındaki her parmak izini bir arama sorgusu (search query) olarak kullanmaktadır. Benzerlik arama sırasında verilen bir arama sorgusu parmak izi için benzer tüm parmak izleri veri tabanından çağırmaktadır. Son olarak işleme sonrası ve eşikleme (postprocessing ve thresholding) adımlarıyla veri tabanından çağırılan en benzer olmayan çiftler kaldırılmakta ve deprem algılama zamanlarının bir listesiyle sonuçlanmaktadır. Bergen (2018) yaptığı çalışmada tek istasyonlu FAST dedektörünü sismik bir ağda birden çok istasyona genişleten bir yaklaşım sunmuştur. FAST deprem algılama dedektörünün akışı için üç yeni algoritma tanıtmıştır: olay-çift çıkarma, ikili sözde ilişkilendirme, olay ayrımı (event-pair extraction, pairwise pseudo-association, event resolution). Bu sayede yanlış algılamaların azaltılması ve algılama hassasiyetinin geliştirilmesi sağlanmıştır.

Şekil 3.7’de FAST’ın depremleri nasıl tespit ettiğine dair üst düzey bir genel bakış sunulmuştur. Yukarıda anlatıldığı üzere oluşturulan veri tabanını çok büyük bir “dosya dolabı” olarak düşünelim. Bu dosya dolabı, her klasörün (grup) aynı kategoride küçük sayıda dosyalar (parmak izi) içerdiği binlerce klasörden (grup) oluşmaktadır. Sürekli verideki tüm zamanların üretilen tüm parmak izlerinden sonra veri tabanına yerleştirilmektedir. Böylelikle benzer diğer parmak izlerini aramak mümkün hale gelmektedir. Parmak izi bir “arama sorgusu” (search query) deprem dalga formuna dönüştürülmektedir. Daha sonra FAST parmak izinin hangi dosyaya ait olduğunu belirlemektedir ve benzer bir parmak izini (ve dolayısıyla benzer deprem dalga formunu) bulmak için yalnızca aynı klasör içinde diğer parmak izlerini aramaktadır. Aynı klasör içinde küçük parmak izi alt kümesini kontrol etmektedir ve veri tabanındaki diğer klasörler içinde konumlandırılan arama sorgusu parmak izlerine benzer olmayan parmak izlerinin büyük çoğunluğunu göz ardı ederek gereksiz karşılaştırmalardan kaçınmaktadır. Gözetimsiz, bilgilendirilmemiş benzerlik arama, her parmak izini bir arama sorgusu olarak kör bir “all to all” araması yapmaktadır (Bergen ve Beroza, 2018).





Şekil 3.7: FAST algoritmasının çalışma prensibini tanımlayan genel bir bakış (Bergen, 2018'den değiştirilmiştir.).

3.2.1 Veri Ön İşleme

FAST'e girdi olarak verilen tek kanallı sürekli dalga formu verisinde bulanabilecek sürekli gürültü kaynaklarından kurtulmak amacıyla öncelikle bir bant geçişli filtre veya veri örnekleme oranını azaltma olarak adlandırılan bir ön veri işlem adımı uygulanmaktadır.

3.2.2. Parmak İzi/Özellik Çıkarımı (Fingerprint Extraction)

Parmak izi çıkarımı (ya da özellik çıkarımı) her bir veri penceresini dalga formu parmak izi olarak adlandırılan seyrek, ikili bir parmak izine (binary fingerprint) dönüştürülmesi işlemidir. Bir dizi özellik olan dalga formu parmak izleri benzerlik arama (similarity search) adımında deprem dalga formlarını karakterize etmek için kullanılmaktadır. Özellik çıkarma yaklaşımı, ses parmak izi yönteminden (Baluja ve Covell, 2008) uyarlanmıştır. FAST deprem algılama modeli, benzer kaynaklara sahip depremlerin benzer dalga formları üreteceğini ve gürültü dalga formlarının ise birbirinden farklı olacağını varsaymaktadır (Bergen, 2018). Parmak izleri benzerlik adımında ham dalga formu sinyalleri yerine kullanılmaktadır. Bu nedenle parmak izleri hem benzerlik arama adımına girdi olarak hem de sismik verilerin özelliklerine uygun hale getirilmelidir.

Gözetimli makine öğreniminde (supervised machine learning), yeni veri sınıfını tahmin etmek için genelleştirebilinen bir model oluşturmak için iki veya daha fazla sınıfın her birine ait bilinen örnekleri kullanılmaktadır. Deprem algılama problemi için, bir dalga formu sınıflandırıcısı hem deprem dalga formu hem de gürültü dalga formunun örneklerini kullanarak bir model oluşturucaktır. Dalga formlarından doğrudan model oluşturmak yerine her dalga formu genellikle bir dizi d özellikleri olarak temsil edilmektedir. O halde sınıflandırma modelini d boyutlu özellik uzayını karar bölgelerine (decision region) bölmek olarak düşünülebilinir. Her bölgeye bir sınıf etiketi atanmaktadır ve belirli bir bölgeye düşen tüm veri noktalarına aynı sınıf etiketi atanır (örneğin; "deprem" ve "gürültü"). FAST ise dalga formu sınıflandırmasından farklı olarak öğrenme için işaretlenmiş (labeled) dalga formu gerektirmemektedir. FAST tarafından kullanılan benzerlik arama modeli diğer dalga formlarına nispeten yüksek benzerliklerine (veya eş değeri olarak düşük mesafeye) dayanan depremleri belirlemektedir; FAST'ta kullanılan algılama istatistiği en yakın komşu mesafesidir ve en yüksek benzerliğe sahip dalga formu çiftleri aday olay dalga formu (candidate event waveform) olarak kabul edilmektedir.

Bergen (2018) çalışmasında istenilen dalga formu parmak izi özelliklerini şu şekilde ifade etmektedir: Dalga formu parmak izlerinin, sinyali gürültüden ayırt etmeyi mümkün

kılmalıdır. Ayrıca bu özelliği taşıyan parmak izi şemaların benzerlik araması için ayırt edici olarak tanımlamıştır. Benzerlik araması yoluyla deprem algılama bağlamında, sinyal bir veya daha fazla deprem dalga formuna yüksek benzerliği (düşük bir en yakın komşu mesafesi) ile gürültüden ayırt edilirken; aksine gürültü hem deprem sinyallerine hem de diğer gürültülere düşük benzerliğe sahip olmalıdır. Bu özelliği sağlayan parmak izi şemalarını, benzerlik araması için ayırt edici olarak tanımlamaktadır.

Parmak izi alma şeması, uygun bir benzerlik veya mesafe ölçüsü ile ele alınmalıdır (Bergen, 2018). Benzerlik ölçüsü verilen iki parmak izi arasındaki benzerliği temsil eden nicel bir değer üretmektedir. Seçilecek benzerlik ölçeği parmak izlerinin özelliklerine (örneğin gerçek değerli mi ikili mi, seyrek ya da yoğun mu) uygun olmalıdır (Bergen, 2018). Parmak izi şeması seçilen benzerlik ölçeğine göre ayırt edici (yukarıda tanımladığı üzere) olmalıdır. Benzerlik metriği, LSH tabanlı benzerlik araması veya *k-d* ağacı (Bentley, 1975) gibi verimli bir arama yönteminde kullanım için de uygun olmalıdır (Bergen, 2018). Ayrıca deprem tespiti için parmak izleri sinyal genliğindeki farklılıklara ve yüksek gürültü seviyelerine karşı güvenilir olmalıdır.

Parmak izi alma şeması uzun zaman periyodları boyunca benzerliklerini koruyan dalga formu parmak izleri üretmelidir. Böylece özellik dönüşümü tüm zaman süresi için sabit olmalıdır. Eğer uyarlanabilir veya dinamik bir şema kullanılıyorsa, uzun zaman periyodlarıyla ayrılmış benzer dalga formlarının yine de yüksek benzerlikte parmak izleri üretmesini sağlamaya özen gösterilmelidir.

FAST algılama modeli şablon dalga formu veya daha öncesinde dalga formu özellikleri ilgili herhangi bir ön bilgiye gerek duymayacak şekilde tasarlanmıştır. Bu nedenle de dalga formu parmak izlerini oluşturmak için kullanılan parmak izi alma şeması için daha öncesinde dalga formu bilgisi gerekmemektedir. Parmak izi alma şeması ya veriden bağımsız (verinin karakterine veya özelliklerinin hiçbirine bağlı olmadan) olabilmekte ya da herhangi bir etiket ya da sınıflama bilgisi içermeyen (uygulanabilmesi için bilinen hiçbir olay dalga formu mevcut olmadığında) veriye dayalı bir yaklaşım olabilmektedir. (Bergen, 2018).

Parmak izi bir dosya ya da yüksek boyutlu veri vektörü gibi bir nesneyi temsil eden kompakt bir izidir (Broder, 1993). Parmak izleri denklem 3.1'de gösterilen bir dönüşüm veya parmak izi şeması $\digamma$ ile hesaplanmaktadır.

$$\digamma: \Omega \rightarrow \{0,1\}^d \tag{3.1}$$

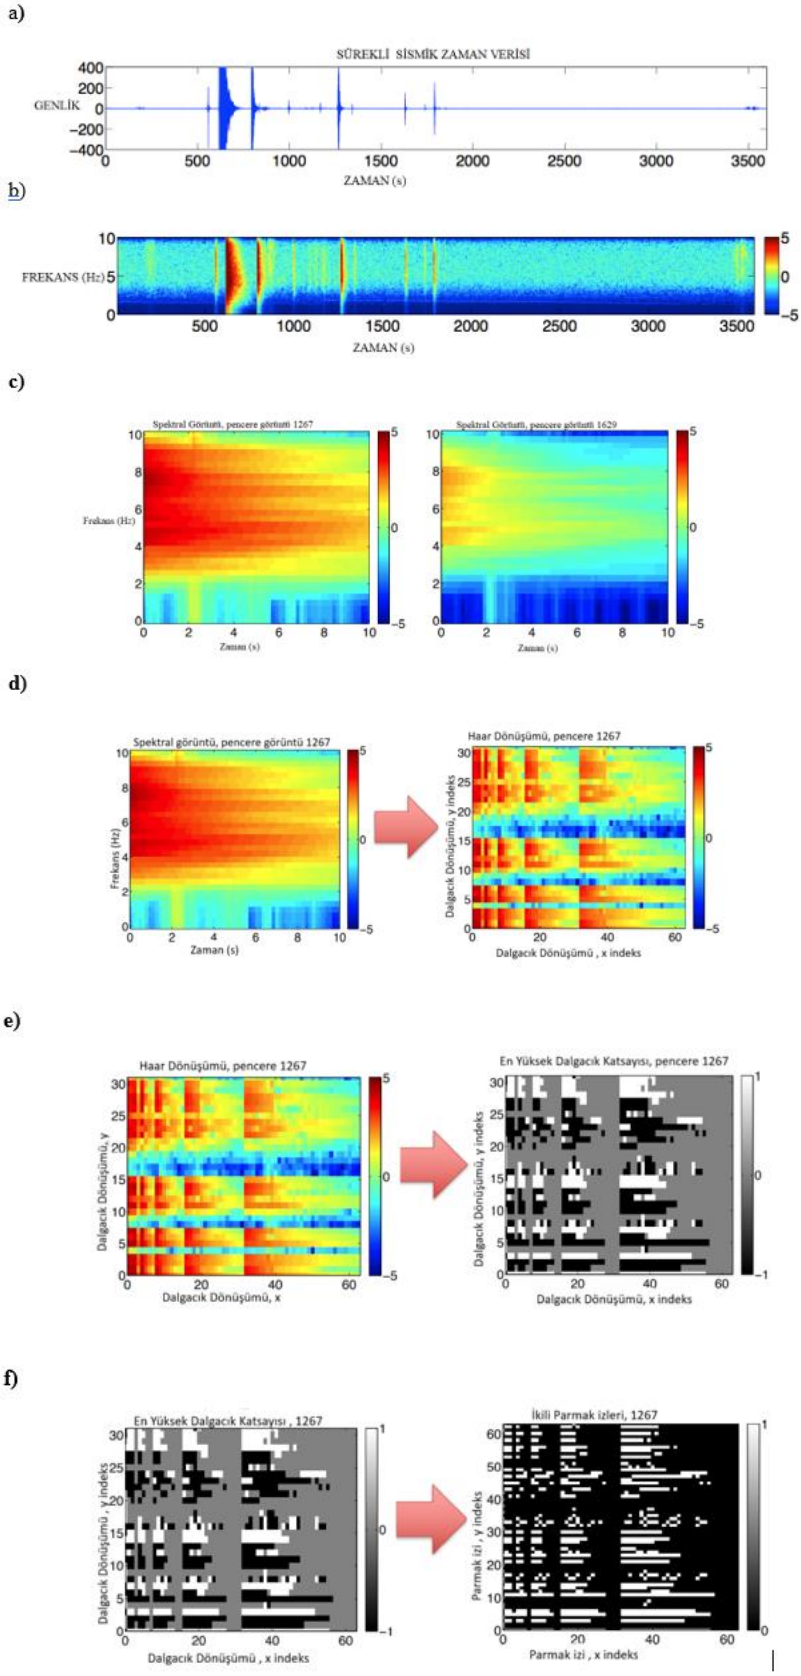
Ƒ, Ω cinsinden bir veri nesnesini, d boyutunun bir bit dizisiyle temsil edilen bir parmak izine eşler (Ω olası veri giriş setleridir örneğin n noktalı sismik dalga formu verisi için $\Omega \subset R$). Genel olarak özellik çıkarımı, bir girdi veri nesnesini bir dizi özelliğe eşleme ve dönüştürme olarak ifade edebilmektedir. Bu dönüşüm genellikle orijinal özellik uzayından daha düşük boyutlu yeni bir özellik uzayına bir eşlemeyi içermektedir. Parmak izi çıkarımı iki önemli özelliği izlemektedir: 1) Denklem 3.1'de gösterildiği üzere eğer x_1 ve x_2 veri nesnelerine karşılık gelen iki parmak izi Ƒ (x_1) ve Ƒ (x_2) birbirlerinden farklı ise o zaman orijinal veri nesneleri x_1 ve x_2'de farklıdır. 2) Denklem 3.2'ye göre eğer orijinal veri nesneleri x_1 ve x_2 farklıysa, o zaman aynı parmak izine eşlemek düşük bir olasılık olmalıdır.

$$Ƒ(x_1) \neq Ƒ(x_2) \rightarrow x_1 \neq x_2 \tag{3.2}$$

$$\mathbb{P}[Ƒ(x_1) = Ƒ(x_2)] << 1 \quad \text{eğer } x_1 = x_2 \tag{3.3}$$

Parmak izleri hashing ile kullanılarak bilgi arama ve geri çağırma görevlerinde kullanılmaktadır. Belge parmak izleri; yinelenen web sayfalarını belirleme, intihal tespit etme, belge çağırma gibi uygulamalarda kullanılmıştır (Manber, 1994; Heintze ve diğ., 1996; Broder, 1997). İçerik tabanlı sesli arama ve erişim problemlerinde meta verilerden ziyade dalga formlarından doğrudan ses kayıtlarını tanımlamayı hedefleyen, genellikle akustik veya ses parmak izleri (Cano ve diğ., 2005b) olarak adlandırılan özellikler kullanmaktadır.

Parmak İzi / Özellik Çıkarma Adımları: Deprem dalga formları seyrek, ikili dalga formu parmak izleri kullanılarak aranmaktadır. Özellik çıkarma işlemi, kısa süreli dalga formlarını seyrek ikili parmak izlerine dönüştürmektedir (Şekil 3.8).



Şekil 3.8: FAST özellik çıkarma aşamaları a) Sürekli zaman serisi verisi b) Spektrogram;log ölçeğinde genlik c) Spektral görüntü d) Haar dalgacık dönüşümü e) Standartlaştırılmış Haar Katsayıları f) İkili Parmak İzi: özellik çıkarma çıktısı (Bergen, 2018'den değiştirilmiştir.).

Veri ön proses: Yüksek düzeyde gürültü içeren frekansları, özellikle algılama (detection) için kullanışlı olmayan dar-bant gürültü veya frekansları ortadan kaldırmak için sürekli dalga formu verilerine bant geçişli filtre uygulanmaktadır. Veri içindeki kayıp ve boşluklar atlanabilir ya da Gausian gürültü ile doldurulabilir. Kesinlikle boşluklar "sıfır"la doldurulmamalıdır. Bu durumda boşluklar aynı "sıfır" parmak izi olarak haritalanacak ve hatalı olarak olası depremler olarak işaretlenecektir. Ön işlemedeki farklılıklar nedeniyle benzer dalga formu çiftinin parmak izlerinin benzerliğini azaltmaktan kaçınmak için tüm veri süresine aynı ön işleme adımları uygulanmalıdır.

Spektrogram: Spektrogram, zaman serisi dalga formu verilerine kısa zamanlı fourier dönüşümü (STFT) uygulanarak zaman-frekans gösterimi haline dönüştürülmesidir. Spektrogram bir pencere uzunluğuna ve pencere gecikmesine sahiptir. Waveprint algoritması ses için logaritmik aralıklı frekans bins kullanırken, FAST sismik veriler için frekans alanında linear aralıklar kullanmaktadır (Bergen, 2018). Spektrogram frekans aralığı verinin örnekleme frekansına ve seçilen bant geçişli filtreye bağlı olarak kesilmelidir. Bant geçişli filtresi dışındaki frekansları içeren frekans bantları filtrelemeden sonra yararlı sinyal bilgisi içermediğinden kesme işlemiyle kaldırılmaktadır (Bergen, 2018). Örneğin 100 Hz de örneklenmiş bir veriye 2-10 Hz aralığında bir bant geçişli filtre uygulandığında, spektrogram frekans genişlikleri 50 Hz'e göre 5te 4 azalmış olur. Şekil 3.8a'da gösterilen sürekli dalga formu verisine kısa zamanlı Fourier Dönüşümü (STFT) uygulanarak sürekli dalga formu verisinin zaman-frekans gösterimi hesaplanmıştır (Şekil 3.8b).

Spektral Görüntü: Spektrogramın zaman ekseni boyunca kısa, örtüşen pencerelere (w_f saniye) ayırılması sonucunda her pencere bir spektral görüntü olarak adlandırılmaktadır. Bu spektral görüntüler sabit boyutlara yeniden boyutlandırılmaktadır: örneğin d_1=32 frekans bins, d_2=64 zaman bins. Boyutlar veri setindeki tüm parmak izleri için aynı olmalıdır ve her boyut bir sonraki adımda Haar dalgacık dönüşümünde hesaplama kolaylığı sağlamak için ikinin katları şeklinde olmalıdır. Bir spektral görüntü sürekli veri içindeki kısa zaman aralıklarına karşılık gelmekte ve sürekli dalga formu verilerinde o aralığa karşılık gelen parmak izine dönüştürülmektedir. Bergen (2018) çalışmasında spektrogram segment uzunluğunu parmak izi penceresi, w_f , ve bitişik parmak izleri arasındaki boşluğu parmak izi gecikmesi, l_f, olarak tanımlamaktadır. Şekil 3.8b'de verilen spektrogram kısa, örtüşen pencerelere ayrılarak Şekil 3.8c' de verilen spektral görüntü elde edilmiştir. Spektral ortam, zaman ortamının aksine bazı değişmezlik olanağı oluşturur. Bu bitişik aralıklar arasında (l_f=1.0 yerine 0.05 sn) daha geniş

gecikmelere izin verir ve toplamda daha az parmak izi üretir. Fakat bu ilişki algılama hassasiyetini düşürür.

Haar Dalgacık Dönüşümü: İki boyutlu ayrık Haar dalgacık dönüşümü ile her spektral görüntü için bir dalgacık görüntüsü elde edilmektedir (Bergen, 2018). Haar dalgacık dönüşümü bir sinyal veya görüntüdeki birden çok ölçekte hareketli ortalamaları ve hareketli farklılıkları hesaplamaktadır. Temel Haar farklı ölçek ve dönüşümlü kare dalgalardan oluşmaktadır. Bu dönüşüm genellikle bir görüntünün seyrek bir temsilini üretmektedir. Görüntü sıkıştırma ve gürültüden arındırma için kullanılmaktadır (Antonini ve diğ., 1992; Donoho ve Johnstone, 1994).

Dalgacıklar, çok çözünürlüklü analiz için matematiksel bir araçtır: hiyerarşik olarak veriyi genel ortalama şekillerine ve en kabadan en ince çözünürlüğe kadar ortalama şekillerinden sapmaları açıklayan ardışık ayrıntı seviyelerine ayrıştırmaktadırlar (Stollnitz ve diğ.,1995). Bir Fourier dönüşümü sinüs ve kosinüs fonksiyonlarına sahiptir, yalnızca frekans alanında konumlandırılır ve yalnızca birkaç katsayı kullanarak periyodik sinyalleri tanımlayabilmektedir. Benzer bir şekilde, ayrık dalgacık dönüşümü (DWT) farklı türde temel fonksiyonlara sahiptir.

Hem zaman hem de frekans alanlarında lokalizedir ve sadece birkaç dalgacık katsayısı kullanan durağan olmayan, patlama benzeri (deprem gibi) sinyaller ifade edilebilir. DWT daha önce STA/LTA deprem algılamasını iyileştirmek ve faz gelişlerini doğru tahminde bulunmak için kullanılmıştır. Şekil 3.8c 'de verilen spektral görüntüye Haar dalgacık dönüşümü uygulanarak Şekil 3.8d 'de verilen Haar dalgacık katsayıları elde edilmiştir.

Dalgacık Katsayılarının Standartlaştırılması: Tüm veri setinin aldığı katsayı değerlerinin dağılımına bağlı olarak her dalgacık katsayısı standartlaştırılmaktadır (Bergen, 2018). Bergen (2018) çalışmasında dalgacık katsayılarının standartlaştırılmasını şu şekilde ifade etmektedir: i. parmak izi için, j. dalgacık katsayısının değeri, $X_j^{(i)}$ standart bir katsayı ile değiştirilir;

$$X_j^{(i)} \leftarrow \frac{X_j^{(i)} - a_j}{b_j} \tag{3.4}$$

Denklem 3.4'te a_j j. dalgacık katsayısının dağılımının merkezinin bir ölçüsüdür ve b_j dağılımın yayılmasının bir ölçüsüdür. Bergen (2018) çalışmasında Denklem 3.5'te verilen ortalama ve standart sapmayı (Zscore) ve Denklem 3.6'da ise medyan ve medyan mutlak sapmayı (MAD) (Hampel,1974) kullanan 2 standardizasyon şeması kullanmayı düşünmüştür:

Z-skor: $a_j=\mu_j=\frac{1}{N_{fp}}\sum_{i=1}^{N_{fp}} X_j^{(i)}, \quad b_j = a_{j=}\sqrt{\frac{1}{N_{fp}}}\sum_{i=1}^{N_{fp}}(X_J^{(\dot{1})} - \mu_j)^2$ (3.5)

MAD: $a_j=\underset{i}{\text{median}}(X_j^{(i)}),\ b_j = \underset{i}{\min}(\left| X_J^{(\dot{1})} - \underset{i}{\text{median}}(X_j^{(i)}) \right|)$ (3.6)

Denklem 3.5'te N_{fp} veri setindeki parmak izi sayısıdır. İstatistikler hesaplanmadan önce (veya spektral görüntüye dalgacık dönüşümü uygulanmadan önce) her spektral görüntü Frobenius 1 normuna ölçeklenmelidir; Özellikler ve dağılımların genliğe bağlı olmaması nedeniyle spektral/dalgacık görüntüleri ölçeklenmektedir. Çünkü gürültünün baskın olduğu sürekli dalga formu verilerinin özellikleri istasyona göre değiştiğinden her kanal için ayrı ayrı hesaplanan Z skoru/MAD istatistikleri kullanarak katsayı standardizasyonu gerçekleştirmek gerekmektedir (Bergen, 2018).

Katsayı Seçimi: Büyüklük bakımından en büyük *K* standardize dalgacık katsayısı seçilmektedir. Bu katsayılar her spektral görüntü için en anormal Haar katsayılarına karşılık gelmektedir ve *K* parametresi genelde % 10-40 aralığında (%5-20 seyreltik bir parmak izi üretebilecek) seçilmektedir (Bergen, 2018).

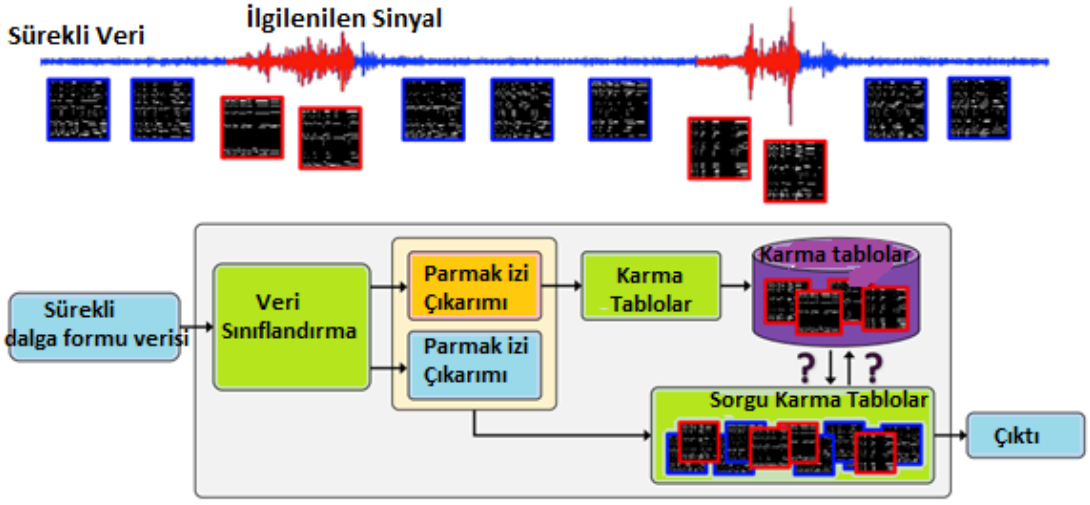
İkili Parmak İzi: Bir sonraki adım olan benzerlik arama adımında benzer parmak izlerini verimli bir şekilde aramak ve depolama için gereken bit sayısını en aza indirmek için ikili (yalnızca 0 ve 1'den oluşan) ve seyrek (çoğunlukla 0) bir parmak izi çıkarılmaktadır. 2 bit kullanılarak her standartlaştırılmış Haar katsayısının işareti sunulmuştur: −1 →01, 0 → 00, 1 → 10. Burada "01" negatif, "10" pozitif ve "00" seçilmeyen katsayılardır. Kısaca ikili, parmak izi (binary fingerprint) konum kodlaması ve 2-bit kodlama kullanılarak seçilen bir Haar katsayısının ifadesidir. Böylece her parmak izi Haar katsayılarını 2 katı bit kullanmaktadır. Her spektral görüntü penceresi 2048 Haar katsayısına sahip olduğundan, her bir parmak izi 2× 2048 = 4096 bittir. Şekil 3.8F'de deprem spektral görüntülerinden türetilen ikili parmak izi gösterilmektedir.

3.2.3. Benzerlik Arama

Parmak izi çıkarımından sonra her spektral görüntü için bir N_{fp} parmak izi koleksiyonu elde edilmektedir. FAST ilk olarak benzer parmak izlerinin birlikte gruplandırıldığı bir veri tabanı oluşturmaktadır. Veri tabanındaki her parmak izini bir "arama sorgusu" (search query) olarak kullanmaktadır. Benzerlik arama sırasında, belirli bir arama sorgusu parmak izi (search query fingerprint) için benzer tüm parmak izlerini veri tabanından çağırmaktadır (Şekil 3.9). Veri tabanı, FAST'ın her sorgu parmak izi için tüm veri tabanını aramak zorunda kalmadan

benzer parmak izlerini tanımlayacak şekilde tasarlanmıştır. Böylece FAST kapsamlı bir arama yerine yaklaşık bir benzerlik araması yaparak yüksek olasılıkla benzer dalga formlarını azaltılmış bir süre de belirleyebilmektedir. Benzerlik arama sonucunda belirlenen benzer dalga formları "aday deprem dalga formları" (candidate earthquake waveforms) olarak adlandırılmaktadır (Yoon ve diğ., 2015).

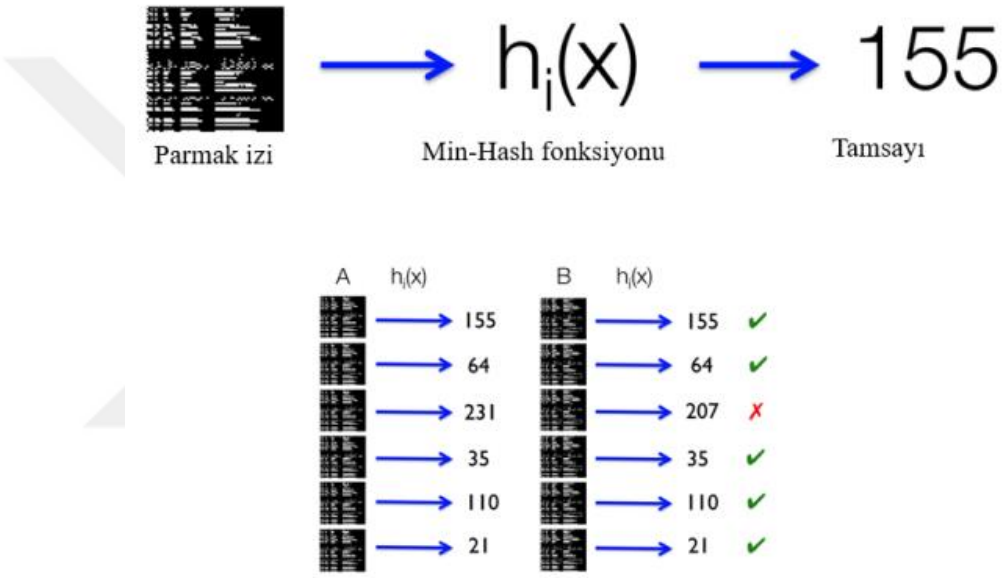
Bergen (2018) yaptığı çalışmada ise benzerlik arama adımlarını şu şekilde tanımlamaktadır: ilk olarak bir parmak izi veri tabanı seti indekslenmekte ya da diğer bir ifade ile dizin haline getirilmektedir. Daha sonrasında benzer dalga formlarını belirlemek için indeks (dizin) sorgulamaktadır. FAST daha öncesinde dalga formu özellikleri hakkında bir bilgi almamaktadır. Bu nedenle FAST benzerlik arama adımı tüm dalga formu parmak izi arasında tekrarlayan veya benzer sinyalleri belirleyebilecek şekilde tasarlanmıştır: parmak izi setini tamamı arama dizininde (search index) depolanmaktadır ve parmak izi setinin tamamı dizine (indekse) karşı sorgulanmaktadır.



Şekil 3.9: FAST arama diyagramı. Sürekli veri setinin tamamı için ikili parmak izleri çıkarılır ve ilgili sinyallere karşılık gelenler "veri tabanı parmak izleri" olarak etiketlenir. Etkin arama için karma tablolarda yalnızca "veri tabanı parmak izleri" saklanır. Benzerlik arama adımında, tüm ikili parmak izleri, karma tablolarında saklanan "veri tabanı parmak izlerine" karşı sorgulanır (Bergen, 2018'den değiştirilmiştir.).

LSH (Locality- Sensitive Hashing); LSH yüksek boyutlu yaklaşık komşu arama (high dimensinaol approximate nearest-neighbor search) için yaygın kullanılan bir metottur. Veriyi oluşturan dalga formu çiftlerinden benzer olmayan çiftlerin karşılaştırılmasından kaçınılmasını sağlayarak benzer olması muhtemel olan "aday çiftler"in (candidate pairs) bir listesini döndürmektedir (Leskovac ve diğ., 2014; Andoni ve Indyk, 2008). Bilgisayar biliminde hashing veri tabanlarındaki öğelerin eklenmesi, aranması ve kaldırılması için kullanılmaktadır

(Levitin, 2012). Her öge bir karma fonksiyonunun (hash functinous) çıktısına bağlı olarak seçilen bir karma kova (hash bucket) içine yerleştirilmektedir (Levitin, 2012). Bir karma tablo (hash table) birçok karma kova (hash buckets) ve öğelerin farklı karma kovalar arasında nasıl dağılacağını belirleyen karma fonksiyonlar (hash functinous) içermektedir (Levitin, 2012).
LSH, bir H fonksiyon sınıfından olan MinHash fonksiyonunu kullanarak verilen bir parmak izini Min-Hash Signature (MHS) olarak adlandırılan bir *p* işaretsiz tamsayı dizisine dönüştürmektedir (Leskovec ve diğ., 2014). Minhash fonksiyonu ile her parmak izinin boyutsallığı 4096 elemanlı bir bit vektöründen daha kısa bir tamsayı dizisine indirgemektedir (Şekil 3.10).



Şekil 3.10: MinHash fonksiyonu ile parmak izinin Min-Hash Signature (MHS) dönüştürülmesi (Broder ve diğ., 2000).

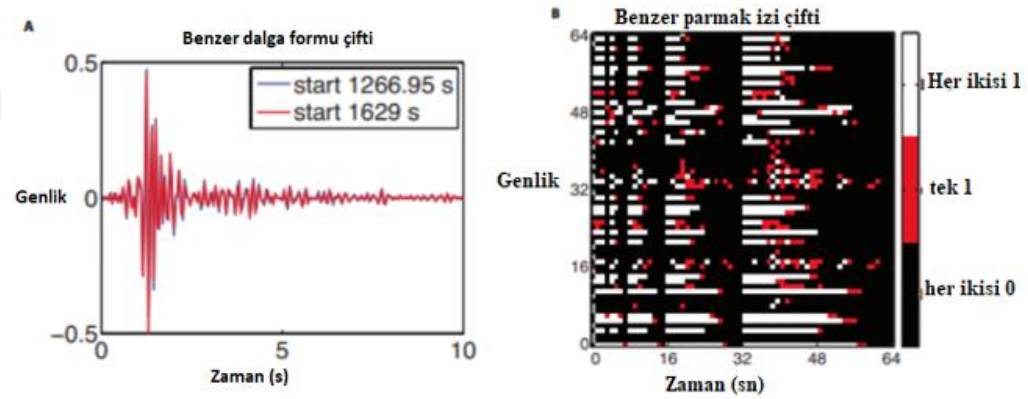
MinHash' ın önemli bir LSH özelliği ise; Bir çift parmak izinin (A ve B olsun) aynı tamsayıya eşlenme olasılıkları Jaccard benzerliklerine eşit olmasıdır (Denklem 3.7). Böylece A ve B parmak izleri arasındaki benzerliği olasılıksal olarak korurken boyutsallığı azaltmaktadır (Leskovec ve diğ., 2014; Baluja ve Covell, 2008).

$$\mathbb{P}_{h\in\mathcal{H}}[h(\mathrm{A}) = h(\mathrm{B})] = \text{Jaccard (A, B)} \qquad (3.7)$$

Template matching ve otokorelasyon metotları iki dalga formu arasındaki benzerliği normalleştirilmiş çapraz korelasyon (CC) kullanılarak ölçmektedir. FAST, LSH uygulamasında parmak izlerini karşılaştırmak için bir benzerlik metriği olan Jaccard benzerliğini kullanmaktadır. A ve B parmak izleri arasındaki Jaccard benzerliği

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \qquad (3.8)$$

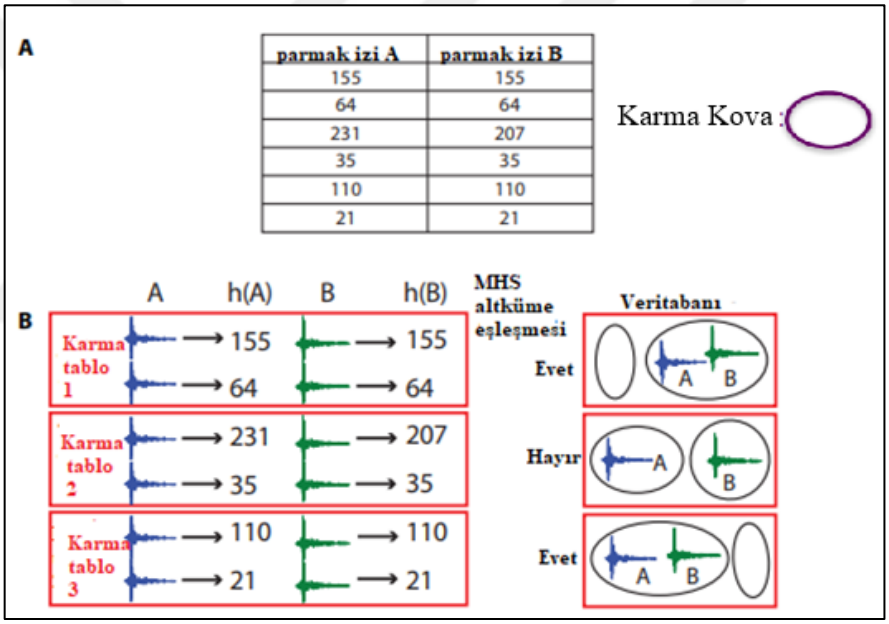
denklem 3.8'deki gibi tanımlanmaktadır (Leskovac ve diğ.,2014). Denklem 3.8'de pay hem A hem de B'deki 1'e eşit olan bit sayısını içerirken buna karşılık payda, A, B veya hem A hem de B'deki 1'e eşit olan bitlerin sayısıdır. Şekil 3.11'de Yoon ve diğ., (2015) tarafından yapılan çalışmadan bir örnek verilmiştir. Şekil 3.11A'da iki çok benzer normalleştirilmiş deprem dalga formları gösterilirken, Şekil 3.11B'de parmak izlerine karşılık gelen Jaccard benzerlikleri gösterilmektedir.



Şekil 3.11: İki benzer deprem için CC ve Jaccard benzerliği. A) İki benzer normalleştirilmiş deprem dalgaformu 2011-01-08 CCOB.EHN sürekli verilerinde 1266.95 s (mavi) ve 1629 s (kırmızı), yüksek CC'ye sahip = 0.9808 (denklem. 3.7), neredeyse mükemmel örtüşüyor. B) Bu dalga formlarına karşılık gelen parmak izleri de yüksek oranda örtüşür, yüksek bir 0.7544 Jaccard benzerliği ile. Beyaz: her iki parmak izi de 1'dir; kırmızı: bir parmak izi 1 ve diğeri 0; siyah: ikisi de parmak izleri 0. Burada Jaccard benzerliği J(A,B) beyaz elemanların sayısının (burada hem A hem de B parmak izleri 1) beyaz ve kırmızı elemanların toplamına bölünmesine eşittir (burada A veya B 1'dir, ancak ikisi birden değildir) (Yoon ve diğ.,2015'den değiştirilmiştir).

Veri tabanın/Arama Dizininin (Search İndex) Üretilmesi; Veri tabanı, *b* karma tablolarından (hash table) oluşan bir koleksiyondur. Diğer bir ifade ile karma tablolar yüksek olasılıkla benzer olan ve aynı karma kova (hash bucket) içinde birlikte gruplandırılan benzer parmak izlerinden oluşan bir veri tabanıdır. Bir karma tabloda (hash table) depolanan her öge bir dizin değeri ya da anahtar ile ilişkilidir. Anahtar öğelerin depolandığı yer olan karma kovaları (hash buckets) işaret etmektedir. Her dalga formu parmak izi için anahtar ya da dizin değeri, yukarıda açıklanan MinHash fonksiyonu kullanılarak atanmaktadır. Spesifik olarak, her bir karma tabloya sabit bir "*r* Minhash fonksiyon dizisi" atanmaktadır. *r* MinHash fonksiyonu ile her parmak izi için bir *r*- tamsayı "MinHash signature" (MHS) üretilmektedir. Daha sonrasında MHS'deki *r* tamsayı değerleri, tek bir karma anahtar (hash key) oluşturmak üzere birleştirilmektedir (Bergen, 2018). Her karma anahtar (hash key) bir karma kovanın (hash

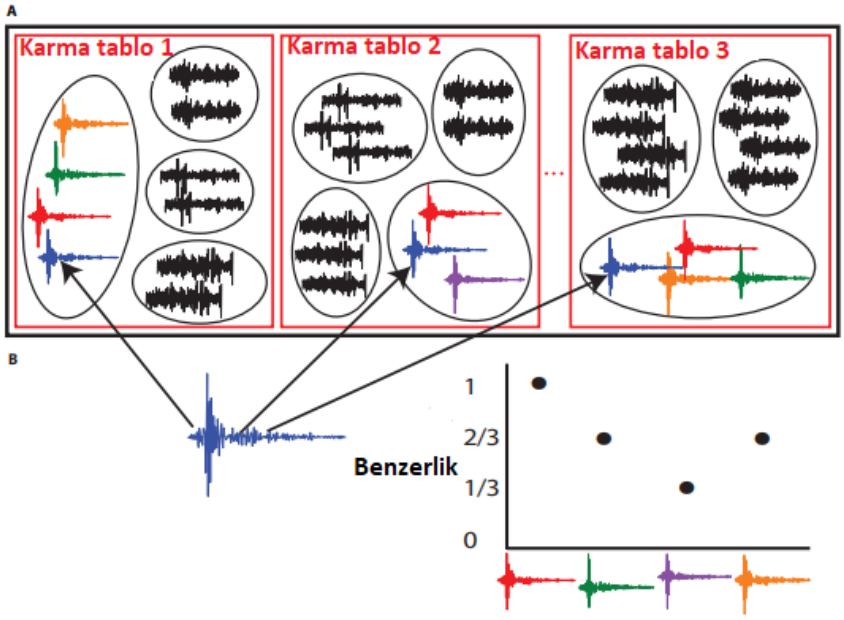
bucket) yerini alan 64 bitlik bir tamsayı dizinidir ve birden çok değer (parmak izi için referanslar) içerebilmektedir. Verilen bir karma tablo (hash table) için eğer *A* ve *B* aynı karma anahtarı (hash key) paylaşıyor ise (eşdeğer olarak, Şekil 3.12'deki MHS alt kümeleri aynı ise) aynı karma kova (hash buckets) içine yerleştirileceklerdir. Aksi takdirde; farklı karma kova içine yerleştirileceklerdir (Leskovec ve diğ., 2014; Baluja ve Covell, 2008). Veri tabanı, karma kovada (hash bucket) parmak izlerinin kendisinden ziyade 32 bit tamsayı referanslarını depolamaktadır. Şekil 3.12'de Yoon ve diğ.,2015 yaptığı çalışmadan iki benzer parmak izi A ve *B* için örnek bir MHS tamsayı dizisi verilmiştir. LSH, MHS kullanarak her parmak izini veri tabanına eklemektedir. Şekil 3.12A'da verilen MHS dizisinin, veri tabanındaki her karma tablosundaki karma kovalara (hash buckets) benzer A ve B parmak izlerinin LSH ile nasıl yerleştirileceği Şekil 3.12B'de gösterilmektedir.



Şekil 3.12: LSH'nin parmak izlerini veri tabanında nasıl gruplandırdığına dair örnek; A) A ve B iki benzer parmak izinin MHS örneği p=6 B) LSH her karma tablosu (kırımızı kutu) içindeki karma kova (hash buckets) (yuvarlak) benzer iki parmak izinin (A ve B) nasıl yerleştirileceğine karar verir. MHS uzunluğu p = 6 ve b = 3 karma tablosu var böylece her bir karma tablo, 6/3 = 2 olan her parmak izinin MHS'sinin farklı bir alt kümesini alır : r = 2 Min-Hash fonksiyonlarının çıktısı. Her bir karma tablosunu ayrı ayrı alarak: A ve B'nin MHS alt kümeleri eşittir, daha sonra A ve B, veri tabanına aynı karma kovaya girer; bu sırasıyla h(A) = h(B) = [155, 64] ve h(A) = h(B) = [110, 21] olduğu karma tablo 1 ve 3 doğrudur. Şekil 3.12A'da p = 6 olan iki benzer parmak izi A ve B için örnek MHS dizilerini göstermektedir. LSH, her parmak izini veri tabanına eklemek için MHS'yi kullanır. Şekil 3.12B'de Şekil 3.12A'da verilen MHS dizileri kullanılarak her bir karma tablosundaki karma tablolara benzer A ve B parmak izlerinin LSH'la nasıl yerleştirileceğini göstermektedir (Yoon ve diğ., 2015'ten değiştirilmiştir).

Veri tabanı İçinde Benzerlik Arama; LSH tarafından oluşturulan veri tabanı benzer parmak izlerini hızlı ve verimli bir şekilde bulunmasını sağlamaktadır. Veri tabanı setindeki her parmak

izi için, yukarıda tanımlanan MinHashing prosedürü tarafından üretilen karma anahtarlar (hash keys) kullanılarak karma tablolardaki (hash tables) her parmak izi için bir referans yerleştirilmektedir. Ayrıca veri tabanındaki her parmak izi bir "arama sorgusu" (search query) olarak kullanılmaktadır. Verilen bir "sorgu parmak izi" için MinHashing prosedürü uygulanarak her karma tablo (hash table) için karma anahtar (hash key) hesaplanmaktadır (Bergen, 2018). Şekil 3.13A'da LSH tarafından oluşturulan bir veri tabanının şeması sunulmuştur. Yüksek olasılıkla benzer parmak izleri aynı karma kova içinde gruplandırılmıştır. Şekil 3.13B'de verilen bir sorgu parmak izi (mavi) için veri tabanındaki parmak izlerinin nasıl aranabileceğini gösterilmektedir. Arama sorgu parmak izi için Şekil 3.12'de gösterilen prosedürler kullanılarak her karma tablodaki karma kovası belirlenmektedir. Daha sonrasında ilgili karma anahtarlar (hash key) kullanarak seçilmiş karma kovalarda bulunan tüm parmak izi referansları alınmaktadır. Çiftleri oluşturan ilk öğe sorgu parmak izi, ikinci öğe ise veri tabanındaki aynı karma kovadaki benzer bir parmak izidir (Yoon ve diğ., 2015). Yoon ve diğ., (2015) tarafından FAST benzerlik; aynı karma kovadaki parmak izini içeren karma tablolarının kesri olarak tanımlamaktadır. Örneğin b=100 karma tablonun en az v=4'ünde görünen çiftin FAST benzerlik eşiği 4/100=0.04'tür ve bunlar "aday çiftler" (candidate pairs) olarak adlandırılmaktadır.



Şekil 3.13: LSH veri tabanı ve benzerlik arama örneği**.** (A) LSH kullanılarak oluşturulan veri tabanı, b = 3 hash tablosu ile (kırmızı kutular); her hash tablosunda birçok oval şeklinde gösterilen karma kova (hash buckets) bulunmaktadır. LSH yüksek olasılıkla aynı karma kovadaki benzer parmak izlerini gruplamaktadır; deprem sinyalleri (renkli) aynı kova içine girmesi muhtemeldir, buna karşılık gürültü (siyah) farklı kovalara gruplandırılmaktadır. B) sorgu (query)dalga formuna (mavi) benzer veri tabanındaki dalga formlarını aramaktadır. Daha sonra, her karma tabloda aynı kovadaki diğer dalga

formlarını almakta ve her dalga formu çifti arasında FAST benzerlik hesaplanmaktadır. Kırmızı dalga formu üç karma tablonun tümünde mavi sorgu dalga formuyla aynı pakettedir. Yani benzerlikleri 1'dir; yeşil dalga biçimi, üç karma tablodan ikisinde aynı kovadadır ve bunun gibi. Bu şekil kolay görselleştirme için dalga formları görüntüleri verilmiştir, fakat veri tabanı deposu karma kova (hash bucket) parmak izleri için referanstır ve bir arama sorgusu dalga formunun parmak izine dönüştürülmesini gerektirir (Yoon ve diğ.,2015'ten değiştirilmiştir.).

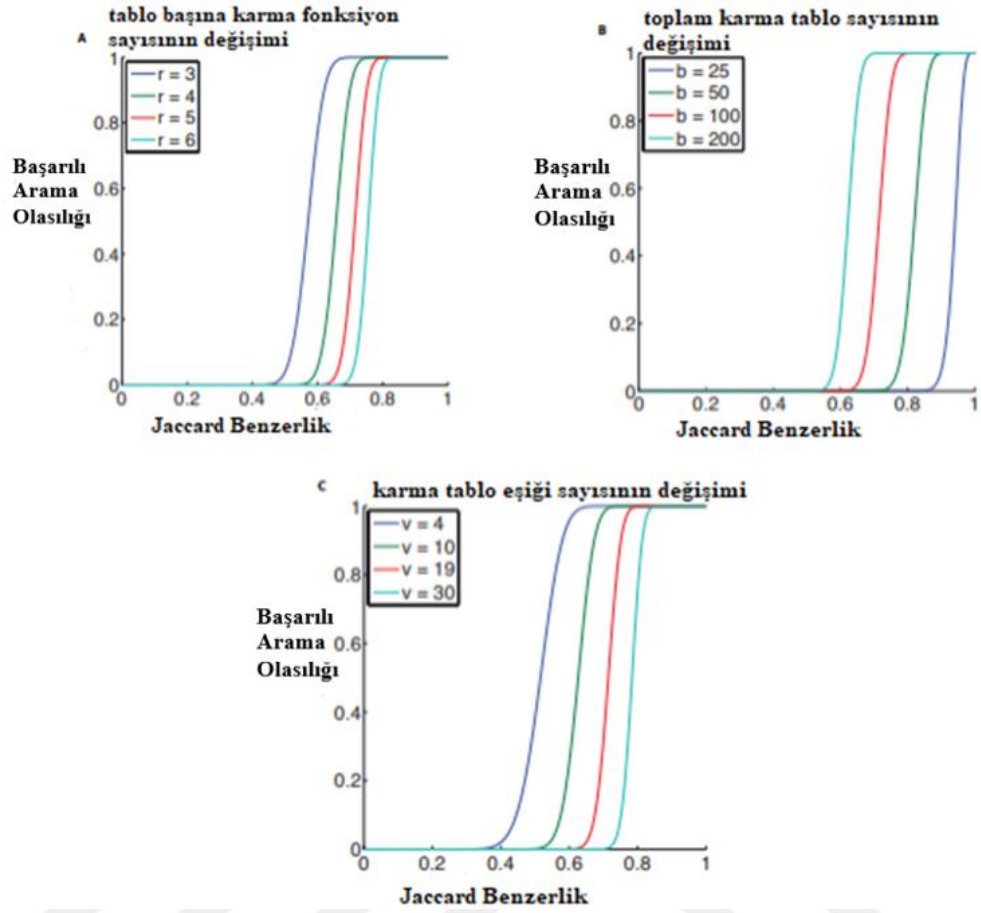
Jaccard Benzerlik ve Algılama Olasılığı; MinHash ile LSH tabanlı benzerlik aramasında bir çift parmak izi için algılama (detection) olasılığı Jaccard benzerliklerine eşittir (Bergen, 2018). Diğer bir ifade ile iki parmak izinin, tablo başına *r* karma fonksiyonuna (r hash functions) sahip *b* karma tabloların en az *v*'sinde aynı karma kovaya yerleştirilme olasılığı Jaccard benzerliklerinin *s* bir fonksiyonu olarak verilmektedir (Yoon ve diğ., 2015):

$$\text{Pr} = 1 - \sum_{i=0}^{v-1} \binom{b}{i} (1 - s^r)^{b-i} (s^r)^i \tag{3.9}$$

$$\binom{b}{i} = \frac{b!}{i!(b-i)!} \tag{3.10}$$

Şekil 3.14'te verilen örnek grafiklerdeki kırmızı eğriler (tüm grafiklerde aynı) denklem 3.9'da verilen *r, b* parametreleri için spesifik olarak seçilen değerler (*r*=5, *b*=100) göz önünde bulundurularak Jaccard benzerliğine karşı başarılı arama olasılıklarını göstermektedir.

Denklem 3.9'da verilen *r, b, v* parametreleri değiştirilerek eğrinin konumu ve eğimi ayarlanabilmektedir. Şekil 3.14A'da *b* ve *v* parametreleri sabit tutularak *r* değerleri değiştirilmiştir; *r* artıkça eğri sağa kayarken başarılı bir arama için daha yüksek bir Jaccard benzerliği gerektirmektedir. Büyük bir *r* değeri için çok sayıda karma kova elde edilirken, bu kovalar içinde ortaya çıkan düşük parmak izi yoğunluğu kaçırılan algılamalara (detections) neden olabilmektedir. Fakat *r* değerinin çok küçük seçilmesi halinde çok az karma kova elde edilmesine ve her kovada çok fazla parmak izi olmasına neden olacaktır. Bu durum da hem benzer parmak izi arama süresi hem de yanlış algılama olasılığı artacaktır. Şekil 3.14B'de *r* ve *v* parametreleri sabit tutularak *b* değerleri değiştirilmiştir; buna göre *b* değeri artıkça eğri sola doğru hareket etmektedir çünkü; çok daha fazla karma tabloya sahip olmak aynı kovada iki parmak izi bulma olasılığını artırmaktadır. Ancak daha fazla bellek gereksinimine, çalışma süresine ve yanlış algılamalara neden olabilmektedir (Leskovec ve diğ., 2014). Şekil 3.14C'de *r* ve *b* sabit tutularak, *v* değerleri değiştirilmiştir; *v* değerleri artıkça eğri daha dik bir eğimle sağa doğru hareket etmekte ve başarılı bir arama için iki parmak izi arasındaki daha yüksek Jaccard benzerliği gerektirmektedir. Ayrıca algılananlar ile algılanamayanlar arasında keskin bir ayrım gerekmektedir.



Şekil 3.14: Jaccard benzerliğinin bir fonksiyonu olarak başarılı bir aramanın teorik olasılığı. Kırmızı eğriler (tüm grafiklerde aynı) şunu göstermektedir: örnek olarak seçilen FAST parametreleri: r = 5 (tablo başına düşen fonksiyon sayısı), b = 100 (toplam karma tablo sayısı) ve v = 19. a) b=100 ve v=19 sabit tutularak r değerleri değiştirilmiştir. r arttıkça eğri sağa kayarken başarılı arama için daha yüksek Jaccard benzerliği gerektirmektedir. b) r = 5 ve v = 19 sabit tutulmuştur. b arttıkça eğri sola doğru hareket etmekte ve daha fazla karma tablo sayısı daha düşük Jaccard benzerliğine sahip parmak izi çiftlerini bulmaya olanak vermektedir. c) r=5, b=100 parametreleri sabit tutularak v değerleri değiştirilmiştir. v arttıkça, eğri daha dik bir eğimle sağa hareket etmektedir ve başarılı arama için iki parmak izi arasında Jaccard benzerliği daha yüksek olmalıdır Ayrıca algılananlar ile algılanmayanlar arasında daha keskin bir ayrım gerekmektedir (Yoon ve diğ., 2015'ten değiştirilmiştir.).

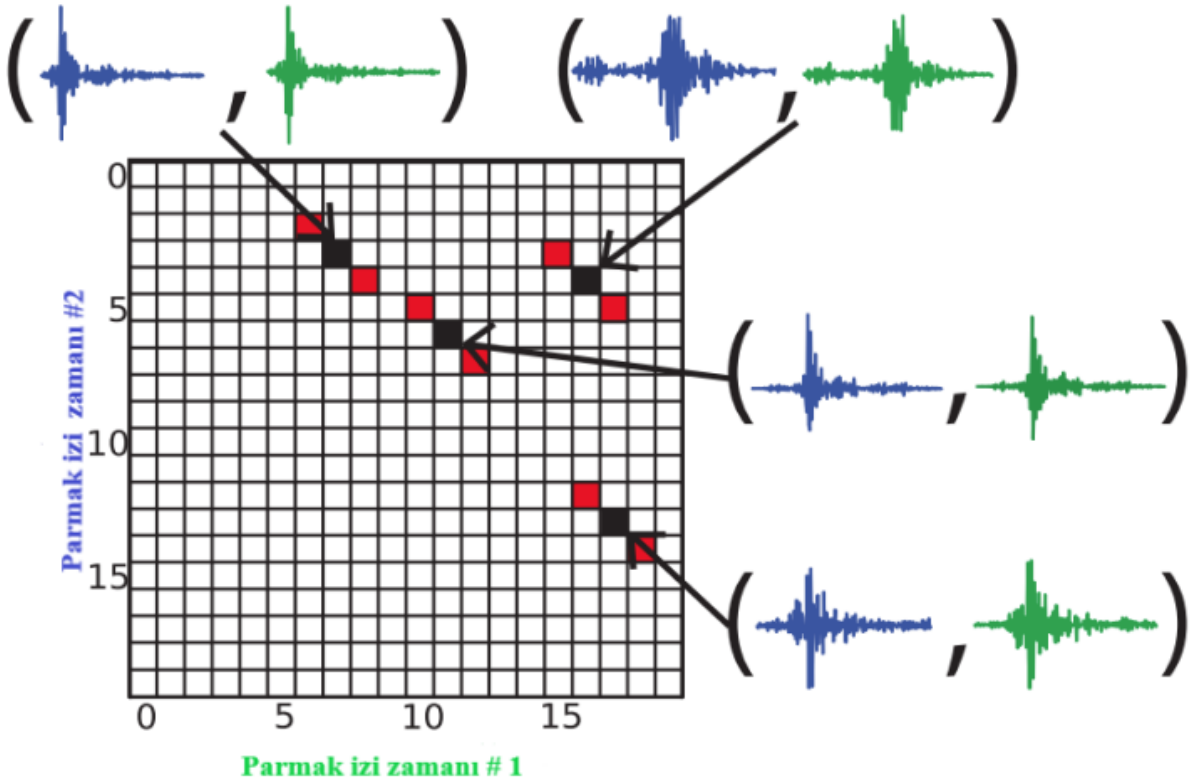
FAST Benzerlik Aramasının Hesaplama Verimliliği; LSH kullanılarak benzerlik aramanın çalışma süresi, karma tablo (hash table) içindeki verilerin dağılımına bağlıdır (sorgulanan karma kovalardaki toplam öge sayısı ile orantılı bir sorgu işlem zamanı). Böylece toplam arama süresi en büyük karma kovanın boyutu tarafından yönlendirilecektir (Bergen, 2018). Tüm N parmak izlerinin aynı olduğu bir durumda her karma tablo N öge içeren tek bir boş olmayan karma kovaya sahip olacaktır. Tam tersi durumda eğer her parmak izi tek bir karma kovaya atanır ise o zaman genel bir O(N) çalışma süresi için her biri O (1) işlem süresine sahip N sorgusu elde edilecektir. Pratikte benzerlik arama süresi tanımlanan şu iki uç arasında olacaktır: $O(N^{1+\rho})$, $0 \leq \rho \leq 1$. Karma kovadaki verilerin dağılımı ve çalışma süreleri aynı zamanda LSH

parametrelerinin (b, r sayısına) ve parmak izi setinin dağılımına bağlıdır. Karma fonksiyon sayısı (r) çarpışma olasılığını ayarlayarak karma kova içindeki yoğunluğu ayarlamaktadır. Yood ve diğ., (2015) yaptıkları çalışma da FAST için bellek kullanımı ve çalışma sürelerinin deneysel ölçeklenebilirliğini sunmuştur. (Bergen, 2018).

3.2.4. Benzerlik Arama Çıktısı ve İşlem Sonrası

FAST, benzerlik arama adımının sonucunda seyrek bir benzerlik matrisi (*M*) üretmektedir (Şekil 3.15). Benzerlik arama adımının en önemli özelliği sadece nispeten yüksek benzerliğe sahip parmak izi çiftlerini geri vermesidir. Düşük benzerliğe sahip tüm parmak izi çiftlerine sıfır değeri atanmaktadır. Böylelikle benzerlik matrisi seyrek hale gelmektedir. Matrisin her satırı ve sütunu belirli bir dalga formu parmak izine karşılık gelmektedir ve matris değerleri parmak izleri arasındaki benzerliğin bir ölçüsüdür (öyle ki M [i, j] = m_{ij} parmak izi i ve j'nin benzerliğini verir). FAST için benzerlik değeri m_{ij}, parmak izi i ve j'nin birlikte bulunduğu karma tablolarının sayısıdır ve onların Jaccard benzerlikleri için olasılıksal olarak ilişkilidir (bkz.Denklem 3.9).

Benzerlik matrisi seyrek olduğundan ve FAST, yalnızca çiftlerin bir alt kümesi için sıfır olmayan benzerlikleri döndürmektedir. Çıktı matristeki sıfır olmayan değerlere karşılık gelen üçlü bir liste şeklinde döndürülmektedir. Her üçlü çiftteki her parmak izinin tamsayı indeksini ve bunlara karşılık gelen benzerlik değerini içerir: (i, j, m_{ij}) ya da (t_i, t_j, m_{ij}) parmak izi i karşılık gelen zaman damgası (timestamp) t_i kullanarak. Her parmak izi için dizin (index) ya da ID sırayla ve verideki herhangi bir zaman boşluğunu hesaba katarak atanmalıdır, öyle ki her parmak izi için zaman damgası ve dizin arasında doğudan bir benzeşme vardır: t_i = i × l_f, l_f bitişik parmak izleri arasındaki zaman gecikmesini kontrol eden parametredir. Çıktının boyutunu sınırlamak için FAST, kullanıcı tarafından seçilen bir eşiği aşan benzerliğe sahip üçlüleri sadece döndürmektedir, $m_{ij} \geq \tau 0$, yinelemeleri önlemek için $i < j$ olanlar için (Bergen, 2018).



Şekil 3.15: Sürekli sismik verinin tek bir kanal için seyrek benzerlik matrisi olarak FAST çıktısının gösterimi. Her kare bir çift parmak izini temsil etmektedir. Matris seyrektir. Çünkü; LSH aramayı oldukça benzer parmak izi çiftleriyle sınırlıyor. Siyah kareler oldukça yüksek benzerliğe sahiptir ve oldukça benzer dalga formlarının oluştuğunu göstermektedir. FAST benzerlik ölçeği aynı karma kovadaki her parmak izi çiftini içeren karma tabloların bir kesridir. Sonraki aşamalarda yinelenen çiftlerin (tekrarlayan çiftlerin) kaldırılması da dahil olmak üzere olay algılamalarının bir listesini elde etmek için işleme ve eşikleme gereklidir.

3.2.5 Sonraki adımlar: Benzerlik Eşikleme

Benzerlik arama çıktısını bir aday olay algılama listesine (candidate event detection) dönüştürmek için ek adımlar gerekmektedir (Şekil 3.16). Yoon ve diğ., (2015) her parmak izi i ID (timestamp) için maksimum benzerlik değeri alarak her parmak izi ID (timestamp) için bir algılama istatistiği, y(t), elde etmiştir: y(t_i) = max(j, k):j=i or k=i(m_{jk}). Daha sonra bu algılama istatistiğine ikinci bir eşik uygulayarak elde edilen algılama süreleri aralıklar halinde gruplandırılmaktadır. Böylece herhangi bir t_i zamanı y(t_i) $\geq$ τ_1 bir olay tespiti ile eşlenmektedir.

3.2.6. Bir Sismik Ağ Üzerinden Benzerliğe Dayalı Algılama

İlk yayımlanan çalışmalarda (Yoon ve diğ., 2015; Bergen ve diğ., 2016; Yoon ve diğ., 2017) FAST tek bir istasyonda, tek ya da üç bileşenli sürekli sismik verideki benzer deprem dalga formlarını algılamak için kullanılmaktaydı. Benzerliğe dayalı dedektörlerde, kalıcı

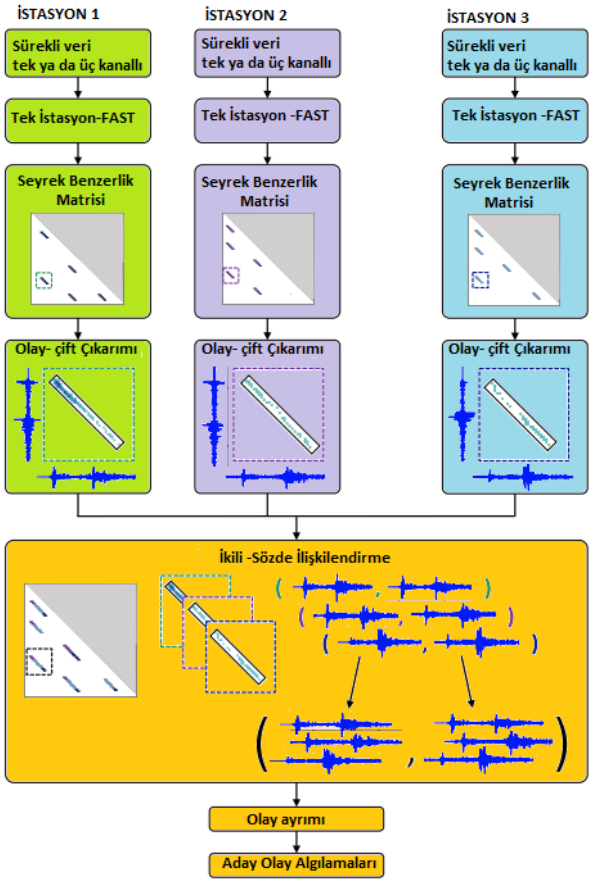
gürültü kaynaklarının üretebileceği tekrarlayan ya da benzer dalga formları nedeniyle özellikle tek istasyon düzeyinde yanlış algılamalara karşı oldukça duyarlıdır. Bu nedenle yüksek hassasiyeti (yani düşük bir yanlış algılama oranı) korumak için FAST'in çok istasyonlu algılama için genişletilmesine ihtiyaç duyulmuştur. Bu amaçla son işlem adımındaki tek istasyon algılama sonuçlarını birleştiren çok istasyonlu bir algılama yaklaşımı sunulmuştur. Bu yaklaşımda FAST uygulaması sonucunda elde edilen çıktıya yeni üç adımlı ağ algılama ardışık düzeni (Şekil 3.16) uygulanmıştır: olay çifti çıkarma (event-pair extraction), ikili sözde ilişkilendirme (pairwise pseudo-association) ve olay ayrımı (event-resolution). Ancak bu yaklaşım genel bir yaklaşımdır. Yöntem bir ağ üzerinde gözlemlenen olayları tanımladığı için (tipik enerji tabanlı deprem dedektörlerindeki faz varışlarına uygulandığında "ilişkilendirme" (Mykkeltveit ve Bungum, 1984; Ringdal ve Kværna, 1989; Johnson ve diğ., 1997) olarak adlandırılır) çekirdek ağ algılama adımı ikili sözde ilişkilendirme (pairwise pseudo-association) olarak adlandırılmıştır. Yaklaşımın ayırt edici özelliği sismik dalgaların varış zamanları ile ilgili olan ofset zaman bilgilerini kullanmamasıdır ancak bunun yerine algılanan olayları ilişkilendirmek için ikili (pairwise) algılamalardan yararlanmaktadır.

Şablon eşleştirme yönteminde, birden fazla istasyon üzerinden eş zamanlı algılama çok zayıf deprem sinyallerinin (Peng ve Zhao, 2009) tanımlanmasını sağlamaktadır; ağ üzerinden çapraz korelasyon değerlerinin toplanması önemli yanlış algılamalara maruz kalmadan gürültüden sinyalleri ayırt etmeyi kolaylaştırmaktadır. Nispeten birden çok kanal ve istasyonu şablon eşleştirmeye (template matching) genişletmek kolaydır. Çok istasyonlu şablonlar bilinen olaylardan alınan veriler kullanılarak oluşturulduğundan hem ağdaki her istasyonda dalga formu özellikleri (signature) ve göreceli varış zamanları bilinmektedir. Ve hiçbir faz ilişkilendirilmesi gerekli değildir. Göreceli varış zamanlarındaki bazı belirsizliğe izin veren son şablon eşleştirmedeki (Zhang and Wen, 2015) değişimlerde yaklaşık kaynak lokasyonu ve varış zamanları hakkında önceden bilgi gerektirmektedir. Buna karşılık çok istasyonlu algılama için kör benzerlik aramasını genişletme görevi daha zordur. Çünkü ağ üzerinden dalga varışlarının ofseti bilinmemektedir ve her istasyonda göreceli varış zamanlarının belirlenmesi arama sorununun parçası haline gelmektedir.

Yaklaşımın ilk adımı olan olay çifti çıkarma adımı ham FAST çıktısından temel verileri ayıklamaktadır ve her istasyonun çıktısına ayrı ayrı uygulanmaktadır. Bu adımı ikili sözde ilişkilendirme olarak adlandırılan çekirdek ağ algılama izlemektedir. İkili sözde ilişkilendirme aynı kaynak olayla ilişkilendirilebilecek gelen varışların alt kümelerini tanımlamaktadır. Hem

olay çifti çıkarma hem de ikili sözde ilişkilendirme, ikili algılamalar üzerine çalışmaktadır. Son adım olan olay çözümleme de ise bireysel olayların nihai listesini üretmek için gereklidir.

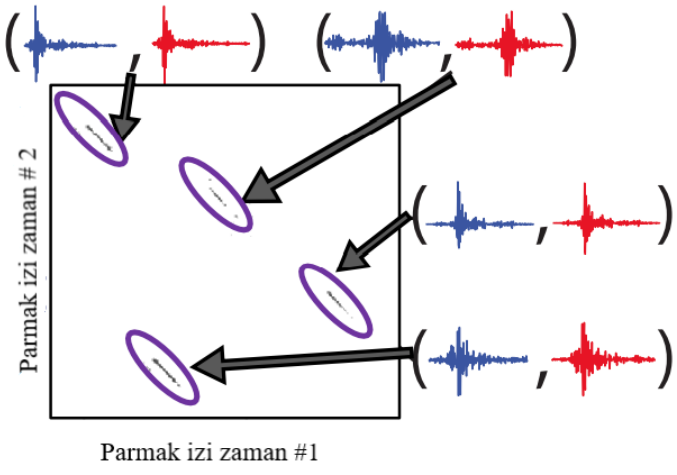
Bergen (2018) çalışmasında ağ algılama algoritmalarında her biri sabit bir zaman süresine sahip dalga formuna karşılık gelen iki "ikili dalga formu parmak izi" (binary waveforms fingerprint) seti ifadesi yerine "parmak izi çifti" (fingerprint pair) terimini kullanmıştır. Her biri gelişigüzel dalga formlarına karşılık gelen, fakat eşit sürede, her ikisi de aynı istasyonda gözlemlenen iki benzer olay kümesine atıfta bulunmak için olay çifti (event pair) terimini kullanmıştır; olay çiftleri bir veya birden fazla örtüşen veya sıralı parmak izi çiftlerinden oluşmaktadır. Bir ağ olay çifti ya da kaynak çifti (network/source event pair) ağdaki birden çok istasyona karşı gözlemlenen bir olay çiftini ifade etmektedir (Bergen, 2018).



Şekil 3.16: Çok istasyonlu FAST algılama hattının diyagramı. Tek istasyonlu FAST her istasyon için seyrek bir benzerlik matrisi üretmektedir. 1) Olay çifti çıkarma (event-pair extraction) adımında her istasyon için seyrek benzerlik matrisi ikili olay algılama (pairwise event detections) listesine dönüştürülmektedir. 2) ikili sözde ilişkilendirme (pairwise pseudo association) adımında sismik ağda birden fazla istasyonda gözlenen olay çiftlerini tanımlanmaktadır. 3) Olay ayrımı (event resolution) ikili olayları (pairwise event) bir "aday olay algılama" (candidate event detection) listesine dönüştürmektedir (Bergen, 2018'den değiştirilmiştir.).

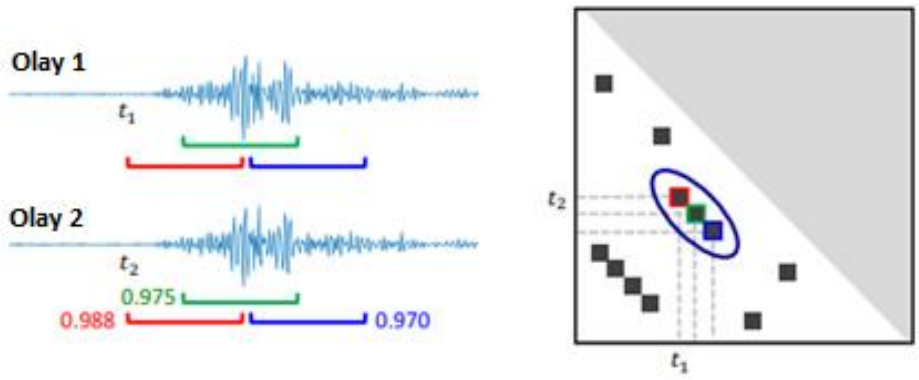
3.2.6.1. Olay Çifti Çıkarma (event-pair extraction)

Bölüm 3.2.5'te anlatıldığı üzere FAST tarafından üretilen seyrek benzerlik matrisi çıktısını aday olay algılama (candidate event detection) listesine dönüştürmek için ek adımlar gerekmektedir. FAST 'in çıktısı kısa aralıklı dalga formlarına karşılık gelen ve nispeten yüksek benzerliğe sahip bir çift parmak izi (fingerprint-pairs) koleksiyonudur. Algılama (detection) bu kısa süreli dalga formları arasındaki benzerlik ile ilgilenmek yerine olay dalga formu çiftleriyle (event-pairs waveforms) ilgilenmektedir. Bu nedenle tek istasyonlu FAST benzerlik matrisi çıktısındaki benzer olay dalga formu çiftlerini belirlemek için ek adımlar gerekmektedir. Bu adımlardan ilki olan olay çifti çıkarma (event-pair extraction) sismik bir ağdaki her kanal veya istasyondaki benzerlik matrisi için ayrı ayrı uygulanmaktadır. Olay çifti çıkarma adımı, sözde ikili ilişkilendirme (pairwise pseudo-association) için gereken giriş formatındaki bir olay çiftleri listesi halinde düzenlemektedir. Olay çifti çıkarma (event-pair extraction) bir veri tekilleştirme adımı (deduplication) olarak çalışmaktadır. Parmak izleri yerine olaylar açısından ikili algılamaları (pairwise detection) temsil ederek FAST'teki çıktıyı sıkıştırmaktadır ve aşırı tek istasyon algılamaları ortadan kaldırmak için gelişmiş eşik sağlamaktadır. Olay çift çıkarımı her olay çiftine karşılık gelen tüm tek (individual) parmak izi çiftlerini toplamaktadır ve aynı olay çiftine ait tüm parmak izi çiftleri benzerlik matrisinde köşegenler boyunca hizalanmalıdır. Bu nedenle, olay çifti çıkarma algoritması seyrek benzerlik matrisinde dar, çapraz kümeleri tanımlamaktadır ve her küme, bir çift benzer olay dalga formunu temsil etmektedir (Şekil 3.17). Her olay çifti/kümesi yalnızca iki olay için zaman bilgisi ve benzerliklerinin nicel bir özetini içeren temel bilgileri saklamaktadır. Bu aşama da küçük bir küme boyutu veya düşük benzerliğe sahip olay çiftlerini kaldırmak için ikincil bir eşik kullanılabilinmektedir (Bergen, 2018).

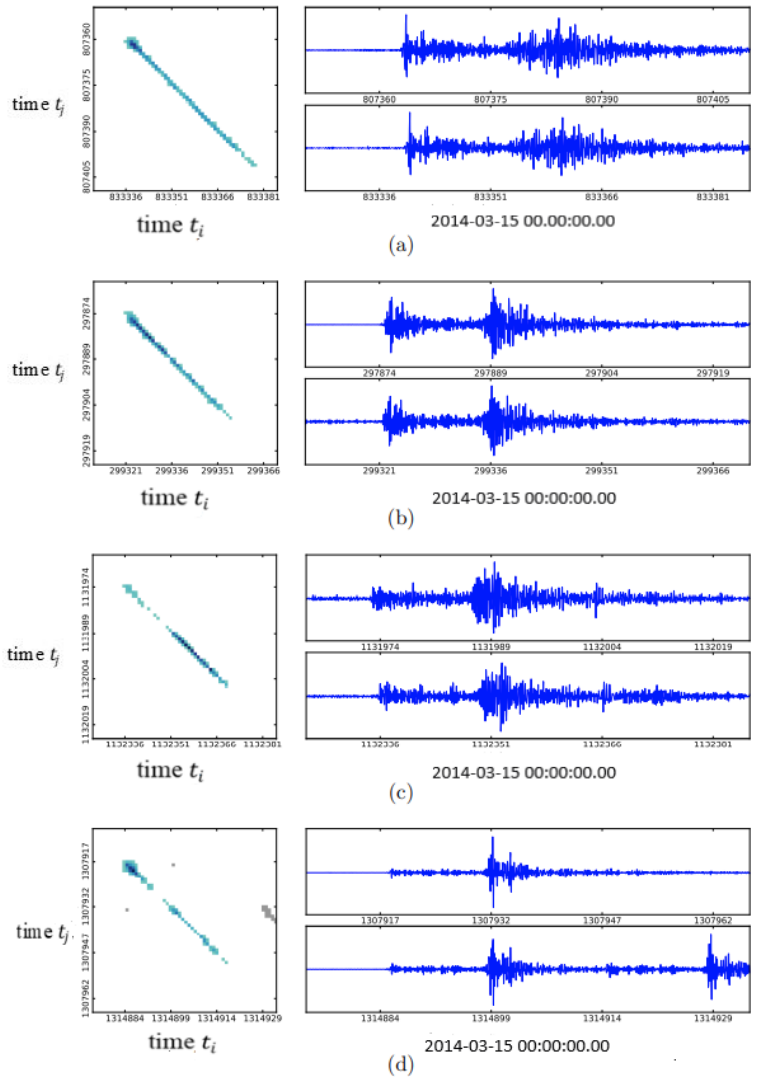


Şekil 3.17: Matristeki gruplara karşılık gelen potansiyel deprem algılamaları (Bergen, 2018'den değiştirilmiştir.).

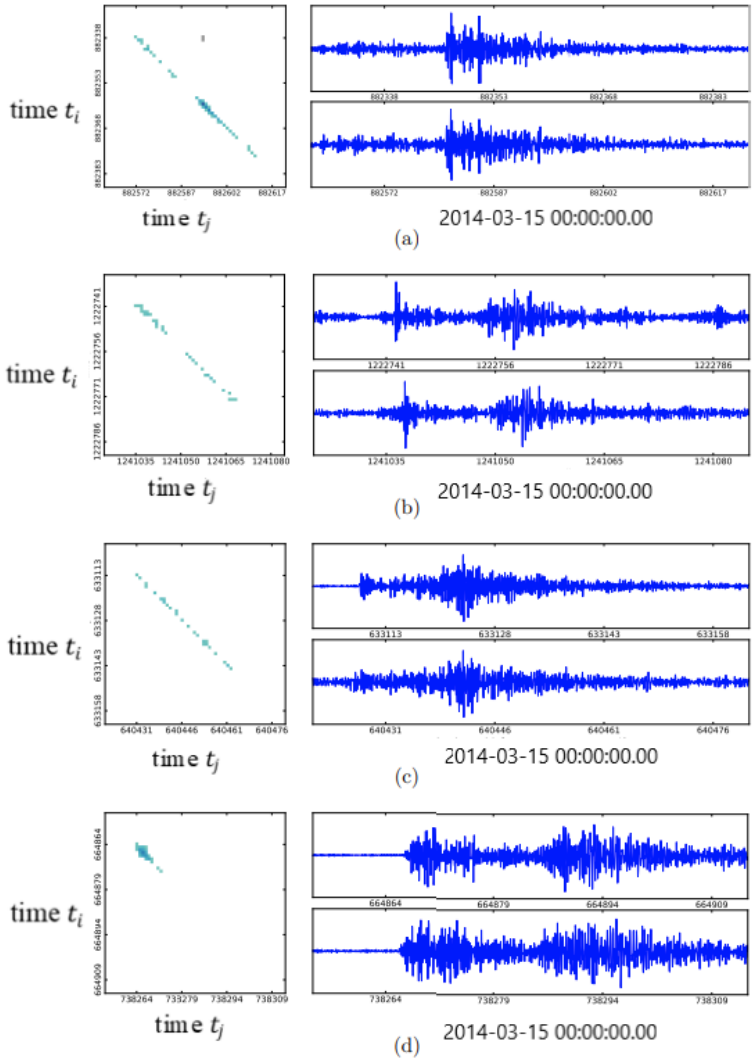
Olay Çıkarma Modeli (Event Pair Modeli); FAST, her kısa, örtüşen dalga formu segmentlerini bir dalga formu parmak izine eşlemek için kayan bir pencere kullanarak sürekli veriyi işlemektedir. Etkili benzerlik arama adımı seyrek benzerlik matrisi şeklinde döndürülen benzer parmak izi çiftlerini belirlemektedir. Tek bir benzer olay çiftinin çoklu algılamalar (parmak izi-çiftleri) üretmesi beklenmektedir. Çünkü örtüşen bitişik zaman pencereleri ve bir olay dalga formu tek bir parmak izi penceresinden daha uzun süreli olabilmektedir. Eğer $t_1$ve t_2 zamanlarına karşılık gelen parmak izleri yüksek benzerlik gösteriyor ise özellikle bitişik parmak izleri arasında önemli örtüşmeler olduğunda (parmak izleri arasındaki gecikme,l_f, parmak izi penceresi uzunluğuna, w_f kıyasla küçük olduğu durum da) t_1+l_f ve t_2+l_f zamanlarına karşılık gelen parmak izleri de aynı zamanda yüksek benzerliğe sahip olmalıdır (Şekil 3.18). Sonuç olarak (çoklu algılamalar) parmak izi çiftleri ayrık benzerlik matrisinde bir köşegen boyunca sıkıca kümelenmiş olarak görüneceklerdir. Benzerlik matrisindeki her köşegen olaylar arası sabit bir zamana (t_i-t_j) karşılık gelmektedir. Benzer parmak izi çiftlerin listesi ayrık benzerlik matrisindeki köşegen yapılar belirlenerek benzer olay çiftlerin bir listesine dönüştürebilmektedir. Şekil 3.19, 3.20 ve 3.21'de seyrek benzerlik matrisindeki diyagonal küme örneklerine karşılık gelen olay çiftleri verilmiştir. Her zaman tüm olay çiftleri benzer deprem dalga formu çiftlerine karşılık gelmemektedir. Şekil 3.21'de FAST tarafından tespit edilen gürültüye karşılık gelen olay çifti gösterilmiştir.



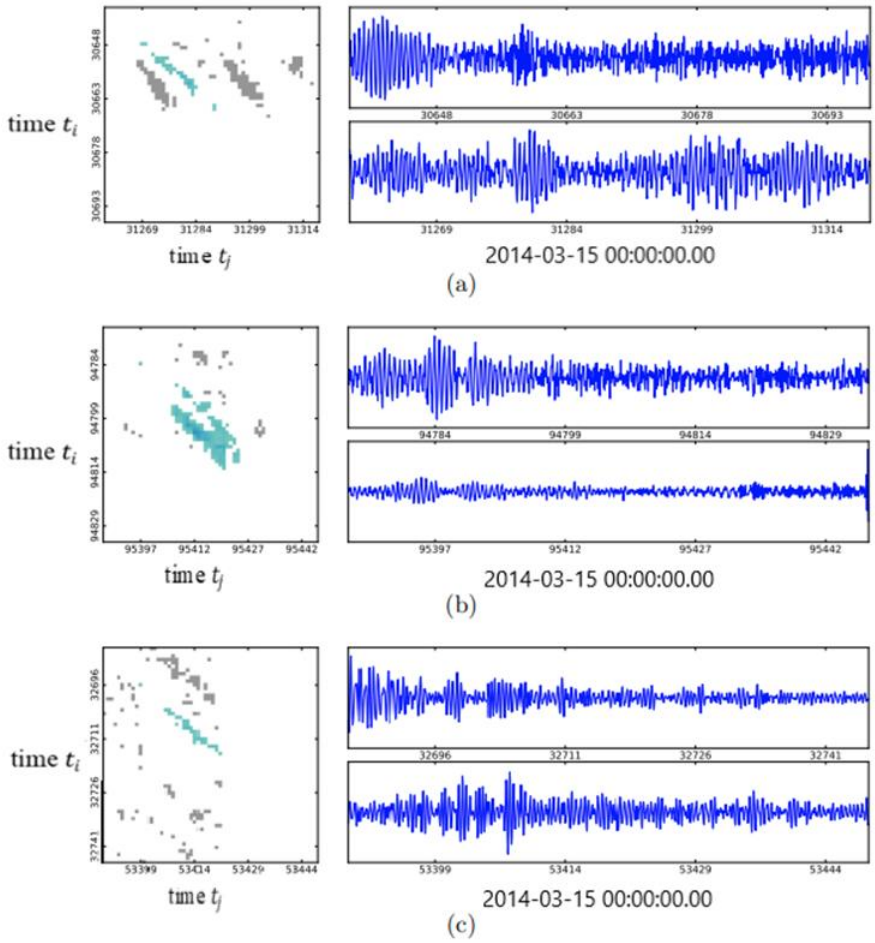
Şekil 3.18: Olay çıkarma modeli: Benzerlik matrisindeki köşegen yapılar tek bir olay çiftinin (event pair) çoklu algılamalarına karşılık gelmektedir. Varış zamanları t_1 ve t_2 olan olay1 ve olay2 için sırasıyla, parmak izleri (t_1 ,t_2), (t_1+l_f, t_2+ l_f), ve (t_1+2l_f, t_2+2l_f) arasında benzeşme (correspondence) vardır. Burada belirtilen l_f bitişik kayan pencereler arasındaki zaman gecikmesidir. Üç çift benzer parmak izi çifti için birinci ve ikinci olay çifti arasındaki geçen süre t_2 -t_1 'dir. Dalga formlarına karşılık gelen normalleştirilmiş çapraz korelasyon (cross correlation) verilmiştir (Bergen, 2018).



Şekil 3.19: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: Sol taraftaki paneller tüm parmak izi çiftlerinin mavi renkte tek bir olay çiftine atandığı küçük bir seyrek benzerlik matrisine karşılık gelmektedir (koyu gölgeler daha yüksek benzerliğe karşılık gelmektedir.). Diğer tüm parmak izi çiftleri gri renk ile gösterilmiştir. Sağ panellerde ise seyrek benzerlik matrisi bloğundaki seçilen satır ve sütunlara karşılık gelen iki sürekli dalga formu verisi aralığını göstermektedir. Yukarıdaki örnekler hem birçok benzer parmak izi çifti hem de bazı yüksek benzerlikli parmak izi çiftler ile nispeten güçlü algılamalardır. Yukarıda (d) (PSGCX.BHZ) istasyonunda 1307932 zaman damgası dalga formu 1314899' deki ile benzerdir (mavi renk ile gösterilmektedir.). 1314929 'ki dalga formu ise gri olarak gösterilmektedir (Bergen, 2018'den değiştirilmiştir.).



Şekil 3.20: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: daha düşük sinyal gürültü oranına sahip olay- çift algılamaları. Yukarıda verilen örnekler nispeten zayıf algılamalardır. Olay çift çıkarımı bu durumlar için oldukça kullanışlıdır. Çünkü bireysel parmak izlerinin (individual fingerprint) nispeten düşük benzerliğe sahip olmasına rağmen bu olay çiftleri korunacaktır. (a) (PB01.BHZ), (b) (PATCX.BHZ), (c) (PSGCX.BHZ), (d) (PATCX.BHZ) bu olay çifti için yalnızca benzer olarak tanımlanan ilk P varışları (Bergen, 2018'den değiştirilmiştir.).



Şekil 3.21: Olay-çifti çıkarımı (event-pair extraction) ile tanımlanan olay- çifti (event-pair) örnekleri: yanlış algılamalar. Yukarıdaki algılamalar muhtemel yanlış algılamalardır. Bu algılamalar ikili sözde ilişkilendirme (pairwise pseudo association) ve olay çifti pruning ile elimine edilecektir. (a) (PB01.BHZ) Olay çifti çıkarma, her köşegen matriste birbirine yakın böyle birden fazla yapılar olsa bile her köşegen yapıyı ayırmaktadır. Bu matris bloğundaki model, 30648-30663 zaman damgalarına (timestamp) karşılık gelen dalga formunun 31269 ve 31314 arasındaki zaman damgalı örtüşen dalga formlarına benzerdir. (b) (PB01.BHZ) nispeten geniş aralıklı olay çiftleri ilişkili gürültü nedeniyle yanlış algılama olma eğilimindedir. Sonuç olarak olay çiftleri için maksimum bir genişlik ayarlanması tavsiye edilmektedir. Böylece yalnızca gerçek algılamaların daha karakteristik olan çapraz yapıları ikili sözde ilişkilendirmeye geçirilmektedir. (c) (PATCX. BHZ) bazı olay çiftleri, kümenin özelliklerine (örneğin genişlik) bağlı olarak ortadan kaldırılabilir, yalnızca kümenin özelliklerine dayanarak doğru tespitleri yanlış tespitlerden ayırt etmek genellikle zordur. İkili sözde ilişkilendirme yoluyla komşu istasyonlardan algılama sonuçları gibi ek bağlam bilgileri, yanlış veri yığınını ortadan kaldırmak için gereklidir (Bergen, 2018'den değiştirilmiştir).

Olay-çifti özeti; Ağ algılama için sözde ikili ilişkilendirmeye bir girdi olarak sadece temel bilgileri iletmek ve çıktının boyutunu azaltmak amaçlanmaktadır. Kısacası her olay-çifti için bir özet oluşturulmaktadır. Her *C* kümesi için olay-çifti özeti kümeye atanan parmak izi-çiftlerini içeren sınırlayıcı kutunun koordinatlarını ve iki olay arasındaki benzerlik derecesini yakalayan özet istatistikleri içermektedir. Her *C* kümesinin elemanı olan parmak izi çiftleri için bir sınırlayıcı kutuyu (bounding box) şöyle tanımlayabiliriz:

$$(dt_{min}^{(C)} = \min_{(i,j)\in C}(t_j - t_i) , dt_{max}^{(C)} = \max_{(i,j)\in C}(t_j - t_i), t_{min}^{(C)} = \min_{(i,j)\in C} t_i, t_{max}^{(C)} = \max_{(i,j)\in C} t_i) \quad (3.11)$$

İlk iki koordinatın yeri olan $dt_{min}^{(C)}$, $dt_{max}^{(C)}$ kümeye atanan parmak izi- çiftleri için köşegen koordinant değerlerinin aralığını vermektedir. Üçüncü ve dördüncü koordinantlar olan $t_{min}^{(C)}$,$t_{max}^{(C)}$ koordinant değerlerinin aralığını vermektedir.

C kümesindeki her olay-çifti (event-pair) için kümedeki parmak izi çiftlerinin sayısı ($ndet^{(C)}$), kümedeki herhangi bir parmak-izi çiftinin en güçlü benzerlik değeri ($pk^{(C)}$) ve kümeye dahil parmak- izi çiftlerinin benzerlik değerlerinin tümünün toplamını (veya hacmini) içeren özet istatistikler hesaplanmaktadır:

$$(ndet^{(C)}=|C|, pk^{(C)}= \max_{(i,j)\in C}(m_{ij}), v^{(C)}=\sum_{(i,j)\in C}(m_{ij})) \quad (3.12)$$

Olay- çifti çıkarma FAST çıktısını daha fazla analiz veya doğrulama için kullanışlı bir formata dönüştürmektedir. FAST aynı olay çifti ile ilişkili düzinelerce parmak izi çiftleri verebilmektedir. Fakat bu analiz parmak izlerinden ziyade olaylarla ilgili ilgilidir. Olay çifti çıkarma analiz için daha yönetilebilir bir toplu çıktı oluşturmak üzere tek bir olay çiftine karşılık gelen parmak izi çiftlerini toplamaktadır. Olay-çifti çıkarma ikili (pairwise) algılamaları korurken yinelemeleri gruplayarak final algılama listesini derleme yönelik olarak ilk adımı sağlamaktadır. İkili algılamalar (pairwise detection) çok istasyonlu algılama (multi-station) için ikili sözde ilişkilendirme tarafından kullanılan ağ algılama modeli için gerekli olmaktadır.

3.2.6.2. İkili Sözde İlişkilendirme (Pairwise pseudo-association)

Sismik ağdaki her istasyon için olay çiftleri (event-pairs) sözde ikili ilişkilendirme algoritmasının girdileridir. İkili sözde ilişkilendirme sismik bir ağda birden fazla istasyon tarafından tespit edilen olayları tanımlamaya yönelik bir çekirdek ağ algılama (core network detection) algoritmasıdır. Aşağıdaki anlatımlar da FAST tarafından benzer dalga formuna sahip iki olay için bir "olay çifti" ifadesi ve aynı olay çiftine ait iki olay arasında geçen süre miktarına "olaylar arası süre" (inter-event time) ifadesi kullanılmıştır.

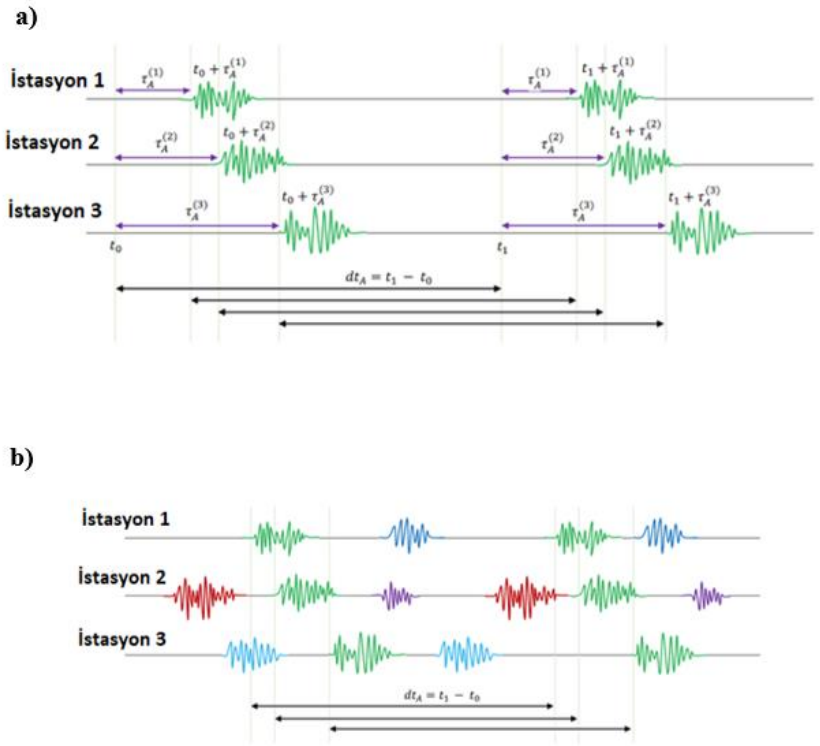
Ağ Algılama Modeli: Tipik bir faz ilişkilendiricisi, bir kaynak modeli ile tutarlı varış zamanlı seçimlerin alt kümelerindeki ağlarda gözlemlenen bireysel fazları gruplamaktadır. İkili sözde ilişkilendirme ağdaki birden çok istasyonda gözlemlenen olay çiftlerini belirlemek için bir model kullanmaktadır. Geleneksel ilişkilendiricilerin (associators) aksine, bir kaynak ile tutarlı olan (yani kaynağı kısıtlamaya, belirlemeye veya doğrulamaya çalışmaz) faz varışları gerektirmemektedir. Bunun yerine önerilen algılama modelinde, olaylar arası sabit zaman aralıkları gereken ağ üzerinden göreceli varış zamanlarının tutarlı olduğu bir olay-çifti

gerekmektedir. Sonuç olarak sözde ikili ilişkilendirme yalnızca algılamalar benzer olay çiftleri olarak döndürüldüğünde uygulanabilmektedir.

Spesifik olarak depremler arası varış zamanları ve ağ birbirine yakınsa, önerilen modelde farklı istasyonlarda kaydedilen iki veya daha fazla örnek çifti aynı kaynak çifti olarak atfedilmektedir. Benzer kaynaklara sahip ve başlangıç zamanları sırasıyla t_1 ve t_2 olan iki olay (olay 1 ve olay 2) düşünelim. Benzer bir kaynağın varsayımı altında t_1+$dp^{(q)}$ ve t_2+$dp^{(q)}$ q istasyonundaki P fazlarının varış süreleri, t_1+$ds^{(q)}$ ve t_2+$ds^{(q)}$ ise S fazlarının varış süreleri olacaktır. $dp^{(q)}$ ve $ds^{(q)}$ kaynaktan istasyon q'ya olan P ve S seyahat süreleridir. Öyleyse tespit edilen belli bir fazdan bağımsız ağdaki tüm istasyonlar için bir çift benzer olay sabit bir olaylar arası zamana (dt) sahip olacaktır (Şekil 3.22).

$$dt = t_2 - t_1 = (t_2 + dp^{(q)}) - (t_1 + dp^{(q)}) = (t_2 + ds^{(q)}) - (t_1 + ds^{(q)}) \quad (3.13)$$

Böylece model fazları açıkça tanımlanmadan doğrudan olay algılamalarına (P varış, S varış veya her ikisine de içerebilir) uygulanacaktır. Bu modelin altında yatan varsayım her istasyonda her iki olay için aynı fazın tespit edildiğidir. FAST gibi benzerlik tabanlı dedektörler için otomatik olarak tutulmaktadır.

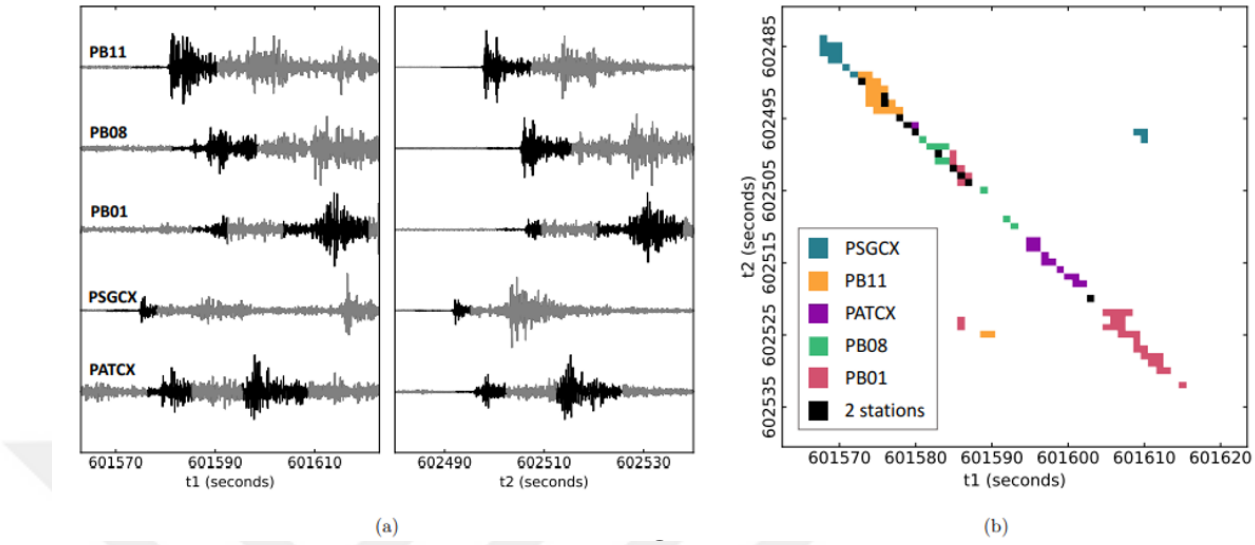


Şekil 3.22: Sözde ikili ilişkilendirme için sabit olaylar arası zamanın gösterimi. a) Başlangıç zamanları t_0 ve t_1 olan iki olaydan oluşan A olay çifti ele alınmaktadır. $\tau_A^{(q)}$, istasyon q'ya P dalga varış süresi olarak kabul edilmiştir. O halde istasyon q'ya varış süreleri t_0+$\tau_A^{(q)}$ ve t_1+$t_A^{(q)}$, ağdaki herhangi q

istasyonu için olaylar arası süre $dt_A = t_1 - t_0$. Aynı mantık sadece P dalgasına değil diğer faz varışlarına uygulanabilmektedir. b) Sabit olaylar arası zaman gereksinimi, bazı kaynak konumlarıyla tutarlılığı doğrulamak için ek bir adım gerekmeden ikili algılamalar olarak ağ üzerinden ilişkilendirilecek olaylara izin veren ek bir kısıtlama sağlamaktadır. Aşağıdaki şemada sadece bir çift olayın (yeşil renk ile gösterilmiştir) benzer bir kaynağı paylaşan her iki olay ile tutarlı ağ üzerinden varış zamanlarına (sabit olaylar arası zaman dt_A) sahiptir. İkili sözde ilişkilendirme, varış zamanları nispeten birbirine yakın (seyrek bir ağda bölgesel depremler için <60 saniye) ve olaylar arası süreler istasyonlar arasında neredeyse aynı (FAST parmak izlerinde kullanılan gecikmenin boyutuna bağlı olarak <1-2 saniye içinde) olay-çiftlerini geçici olarak ilişkilendirmektedir (Bergen ve Beroza, 2018'den değiştirilmiştir.).

Benzer kaynaklı algılama çiftleri için önerilen ağ algılama modelinin basitliği ikili sözde ilişkilendirmenin uygulanmasını nispeten basit hale getirmektedir. Algoritma ağ üzerinden ikili olay algılamalarını (pairwise event detections) tanımlamak için her ikisi de birbirine nispeten yakın zamanda ve aynı olaylar arası sürelere (iki olay algılama arasında geçen süre) sahip olay çiftlerini aramaktadır. Seyrek matris açısından, olaylar arası süre matristeki köşegen koordinata karşılık gelmektedir. Böylece ikili sözde ilişkilendirme aynı matris köşegeni boyunca hizalanmış birden çok olay çiftini tanımlamaktadır. Olaylar arası sabit zaman kriteri, her istasyonda tespit edilen belirli fazdan bağımsızdır. FAST gibi bir olay algılama metodu için bir avantajdır. Özellikle diyagonal kümeler (olay çiftleri) ancak ağ boyunca hareket etmeye izin vermek için zaman içinde kaydırılabilir. Diğer durumlarda koordinant boyunca çok yakın noktalarda hizalanmalıdır (Şekil 3.23). İkili sözde ilişkilendirmeye girdi olarak olay çiftleri gerekmektedir. Bu nedenle olay çıkarımı önce FAST benzerlik arama çıktısına uygulanmalıdır. İkili sözde ilişkilendirme algoritmasında her olay çifti içindeki tüm bireysel parmak izi çiftleri hakkında bilgi gerektirmemektedir. Fakat bunun yerine sadece olay çiftindeki ilk olay için zaman aralığı ve temsili bir köşegen koordinantları (olaylar arası zaman) gerektirmektedir: q istasyonda gözlemlenen olay çifti c için ($dt^{c,q}$,$t_{min}^{c,q}$,$t_{max}^{c,q}$). Olay çifti çıkarma algoritmasındaki parmak izi çiftlerine benzer şekilde, ikili sözde ilişkilendirme algoritmasında tüm istasyonlardan olay çiftleri olaylar arası zamana (dt) göre gruplandırılmaktadır. Bergen (2018) daha sonrasında sırasıyla tüm olay çiftleri arasında dönmektedir ve farklı istasyonlarda gözlemlenen olay çiftler arasındaki izin verilen en büyük zaman boşluğunu tanımlamak için g_N parametresi kullanarak aynı veya köşegen koordinantları paylaşan ve yakın zamanda meydana gelen olay çiftleri gruplandırmaktadır. Olaylar arası süre kısıtlama zorunluluğunun uygulanması (köşegen koordinantlar) ağ üzerindeki tüm olay çiftleri için neredeyse aynı olmalıdır. Böylelikle ağ üzerindeki göreceli varış süreleri için daha rahat bir kriterin kullanılması sağlanmaktadır. Bu, açıkça faz bilgisini kullanmak zorunda kalmadan hepsi tek

bir kaynak çiftine atfedilen ağ üzerinden birden fazla olay çiftini tanımlamanın bir yolunu sağlamaktadır.

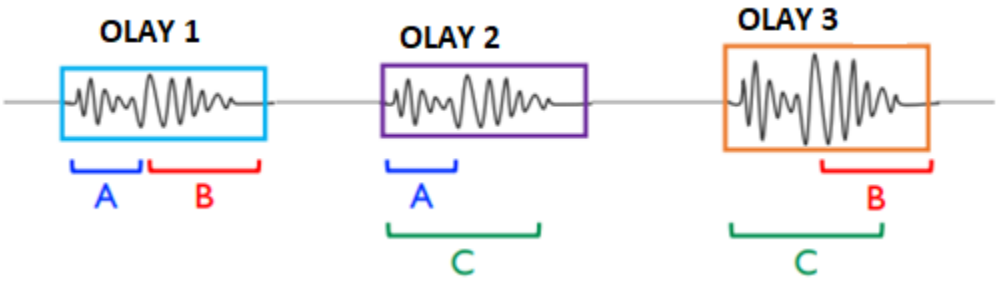


Şekil 3.23: FAST tarafından beş istasyon da tespit edilen, ancak sınırlı zamansal örtüşme olan bir ağ olay çifti örneği. (a) Şili'de Iquique yakınlarında 2014-03-21 tarihinde beş istasyonda gözlemlenen iki olay çifti için dalga formu verisi (gri) gösterilmektedir. Siyah ile gösterilenler FAST tarafından belirlenen benzer dalga formuna sahip kısımlardır. (b) beş istasyondaki tüm için veriler, seyrek ağ benzerlik matrisinde karşılık gelen FAST algılamalar çizilmiştir (Bergen, 2018). Her istasyon için algılamalar farklı renklerde gösterilmiştir. Siyah olarak gösterilen 2 istasyonda parmak izi çifti tespit edilmiştir. FAST tarafından tam olarak 2 istasyonda 11 parmak izi çifti tespit edilirken, 3 istasyonda ise hiçbiri tanımlanmamıştır (Bergen, 2018'den değiştirilmiştir.).

3.2.6.3. Olay Ayrımı (Event Resolution)

Bu noktaya kadar, FAST çıktıları ikili algılamalar (parmak izi çiftleri ya da olay çiftleri) açısından tümünü temsil etmektedir. İkili sözde ilişkilendirme sismik bir ağda birden fazla istasyon gözlemlenen ikili olay algılamalarının (pairwise event detections) bir listesini üretmektedir. Ancak istenen aday olayların (candidate event) bir listesidir. Olay çözümleme algoritması ikili algılamaların listesini alarak bir aday olay listesine çevirmektedir. Tek bir olay birden çok olay çiftine ait olabilir. Olay-çiftleri listesindeki olayların yinelenen tekrarları nihai olay listesini oluşturmak için birbirine bağlanmalıdır. Böylelikle olay çözümleme algoritması tüm bu algılamaları tek bir olay listesine eşlemektedir (Şekil 3.24). Bununla birlikte uygulamada kısmi algılamalar nedeniyle olayları çözümlemek zor olabilmektedir. Örneğin aynı olayın veya karmaşık bir olay dizisi sırasında zaman içinde birbirine yakın meydana gelen çoklu olayların sadece P veya S varışlarının tespit edilmesi gibi. İkili sözde ilişkilendirme de tanımlandığı gibi aynı olayın birden fazla istasyonda gözlemlenmesiyle olayların tutarlı bir şekilde çözmekten ek bir zorluk doğmaktadır. Bu nedenle olay çözümleme yaklaşımının belirli bir veri setine göre uyarlanmalıdır. Geliştirilmiş tek istasyonlu süreç için ikili sözde

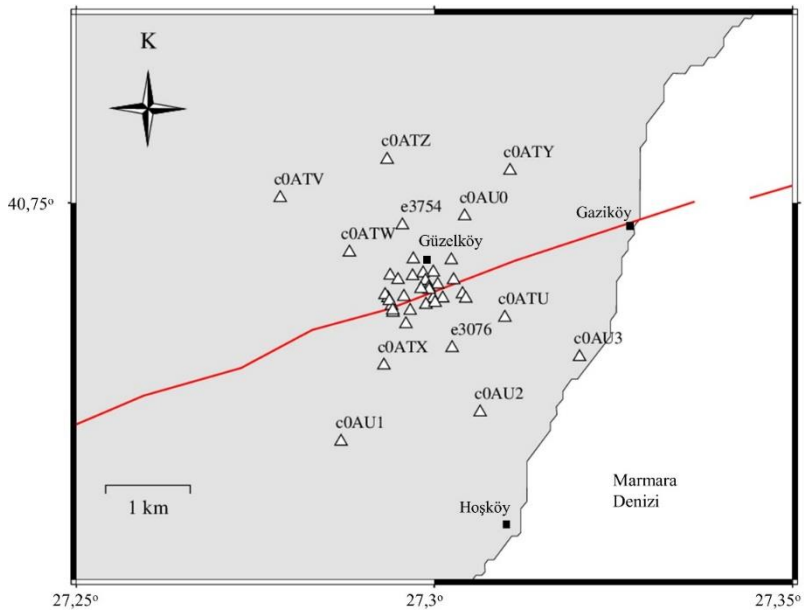
ilişkilendirme adımı atlanarak olay çifti çıkarma ile olay ayrımı adımı (event-pair extraction and event resolution) birlikte kullanılabilir. Sismik bir ağda birden fazla istasyon üzerinden algılama için bu üç işlem adımının tümü kullanılmalıdır.



Şekil 3.24: Olay ayrımı adımını gösteren şema. Olay çifti çıkarma ve sözde ikili ilişkilendirme adımlarına kadar tüm algılamalar ikilidir (pairwise). Olay ayrımı (event resolution), ikili algılamalar listesini (A, B, C olay çiftleri) tek bir olay listesine (a list of unique events) (olay 1, olay 2, olay 3) dönüştürmektedir (Bergen, 2018'den değiştirilmiştir.).

4. BULGULAR

Bu tez çalışmasında STA/LTA ve FAST yönteminde kullanılan bir aylık sürekli veri (01/01/2019-31/01/2019), 2018 yılında Türkiye-Almanya BMBF ikili iş birliği ile oluşturulan bir proje kapsamında Ganos Fayı'nın kara segmenti üzerinde toplam 40 adet istasyondan oluşan MONGAN deprem izleme ağından alınmıştır. MONGAN deprem izleme ağı iki aşamalı çalıştırılan bir ağdır. Bu tez çalışmasında birinci aşama da çalıştırılan MONGAN-1 ağından (Şekil 4.1) seçilen istasyonlar ile çalışılmıştır. Tablo 4.1'de seçilen 9 istasyona ait koordinat bilgileri verilmiştir. MONGAN-1 çok yakın aralıklarla fay zonu üzerine konumlandırılan bir ağdır. Bu lokasyonda istasyon yerleri fayı birkaç noktada kesecek şekilde, faya dik ve paralel olarak bir yıldız şeklinde tasarlanmıştır. İstasyonlar arasında en uzak mesafe ~4 km, en yakın mesafe ise 25 m civarındadır. Fay üzerinde istasyon arası mesafeler kısa tutulurken, faydan uzaklaştıkça mesafeler artmaktadır. Bu çalışmada istasyon seçimi yapılırken birbirine çok yakın istasyonların benzer dalga formlarını kaydedeceği ve tümünün seçilmesi durumunda gereksiz bir veri yüküne neden olacağından, Ganos Fayı'na yakın istasyonlardan temsili ve genel olarak uzak istasyonlar seçilerek analiz yapılmıştır. Tüm istasyonlardaki veriler orijinal olarak 200 Hz'de örneklenmiştir.



Şekil 4.1: MONGAN -1 ağı istasyon dağılımı (üçgenler) (Yalçınkaya ve diğ., 2020). STA/LTA analizinde kullanılan istasyon lokasyonları ayrıca isimlendirilmiştir.

Tablo 4.1: STA/LTA analizinde kullanılan dokuz istasyona ait koordinat bilgileri.

İstasyon. Kanal	Enlem	Boylam
c0ATV SHZ	40.75051	27.27847
c0ATY SHZ	40.7534	27.31056
c0ATW SHZ	40.75051	27.27847
c0ATZ SHZ	40.75458	27.29341
c0AU1 SHZ	40.72463	27.28697
c0AU2 SHZ	40.72775	27.30639
c0AU3 SHZ	40.73362	27.32027
e3099 SHZ	40.75051	27.27847
c0AU0 SHZ	40.74858	27.30423

4.1.STA/LTA ANALİZLERİ

Şekil 4.1'de konumları verilen MONGAN-1 ağından seçilen 9 istasyon (Tablo 4.1) kullanılarak, SEISAN içinde yer alan CONDET programında (bkz. Bölüm 3.1.3) 01/01/2019-31/01/2019 tarihleri arasındaki bir aylık sürekli veri otomatik ayıklama işleminde en temel uygulamalardan biri olan Kısa Zaman Ortalama/ Uzun Zaman Ortalama (STA/LTA) oran yöntemine tabi tutulmuş, daha sonrasında ise manuel olarak tekrar gözden geçirilerek otomatik ayıklamanın kaçırdığı ve yanlış belirlediği olaylar listelenmiştir. Bu tez çalışmasında seçilen farklı STA ve LTA pencere sürelerine bağlı olarak elde edilen otomatik ve manuel ayıklama sonuçlarının karşılaştırması Tablo 4.2'de verilmiştir. Tablo 4.3'te ise Tablo 4.2'de kullanılan farklı STA ve LTA pencere sürelerine karşı ortak olarak kullanılan diğer STA/LTA parametre değerleri verilmiştir. Genel olarak STA süresi bölgesel olaylar için 1-2 sn seçilirken, yerel olaylar için bu süre 0.3-0.5 sn'ye indirilebilir. LTA süresi ise 60 sn'den başlayarak, yerel olaylar için 30 sn'ye indirilebilir. Çalışma kapsamında genel olarak lokal ve küçük depremler hedeflendiğinde STA pencere süresi 0.3 ve 0.5 sn sınanırken, LTA için 60 ve 30 sn pencere süreleri denetlenmiştir. Tablo 4.3'te görüldüğü gibi sabit olarak ayıklama işlemi 2-20 Hz aralığında bir bant geçişli filtre ile başlamaktadır. Tetiklenme oranı 5 olarak belirlenmiştir.

Analizde kullanılan 9 istasyon içinde en az 5 istasyonun tetiklenmesi durumunda bu bir olay olarak listelenmektedir ve sürekli veri içinden 180 sn uzunluğunda kesilerek ayrı bir dosya olarak saklanmaktadır.

Tablo 4.2'de verildiği üzere çalışılan 1 aylık süre kapsamında manuel kontroller sonucu ağ tarafından toplam 262 olay kaydedilmiştir. Yapılan katalog incelemesi (KRDAE ve AFAD katalogları) Tablo 4.4'te verilmektedir. İnceleme sonucu bu olaylardan 124 tanesinin ulusal deprem kataloglarında yer aldığı (büyüklük aralığı: 1.3<ML<4.3), 138 adedinin ise kataloglarda bulunmadığı, bu nedenle sadece bu ağ tarafından kaydedilebildiği anlaşılmıştır.

Bir aylık veri için STA/LTA yöntemiyle yapılan otomatik ayıklama ve manuel ayıklama sonuçları incelendiğinde, genel olarak %32-52 arasında otomatik ayıklama ve manuel ayıklama arasında farklar ortaya çıktığı görülmektedir. Bunların bir kısmı otomatik ayıklamanın yakalamadığı olayların eklenmesi şeklinde iken, diğer kısmı ise yanlış tetikleme nedeniyle olay silme şeklindedir. İlksel genel bir değerlendirme yapmak gerekirse; STA/LTA analizi sonuçlarında hem hatalı algılama oranı çok yüksek, hem de algılama sayıları kullanılan STA-LTA sürelerine çok bağımlıdır.

Tablo 4.2'deki ilk satırdaki STA=0.5 s LTA=60 s pencere süreleri ile yapılan otomatik algılama da hata yüzdesinin (%52.76) en yüksek olduğu görülürken, en son satırda yer alan STA=0.3 s, LTA=30 s pencere süreleri ise en az hata yüzdesine (%32.04) sahiptir. Bu satırda kullanılan STA-LTA süreleri (sırasıyla 0.5sn ve 60sn) denetlemesi yapılan en uzun sürelerdir. Seçilen bu üzün sürelerin özellikle hatalı olay keşfini arttırdığı dikkat çekmektedir. Bu parametrelerde manuel silinen olay sayısı 211'e ulaşmıştır. Bunun tam tersi olarak Tablo 4.2'nin en son satırında kullanılan STA-LTA sürelerinde (sırasıyla 0.3sn ve 30sn) hatalı keşfedilen olay sayısı en düşüktür (75 adet). Kaçırılan olay sayısının genel olarak kullanılan STA-LTA sürelerinden bağımsız olduğu görülmektedir (19-27 adet arası).

Tablo 4.2: Farklı STA ve LTA pencere sürelerine bağlı olarak elde edilen otomatik ayıklama sonuçları.

STA/LTA	Otomatik Ayıklama	Manuel Silinen	Manuel Silinenin Yüzdesi (%)	Manuel Eklenen	Manuel Eklenen Yüzdesi (%)	Net Olay Sayısı	Değişim Oranı
STA=0.5sn LTA=60 sn	451	211	46.78	27	5.98	262	% 52.76
STA=0.5sn LTA=30 sn	394	151	38.32	19	4.82	262	% 43.14
STA=0.3sn LTA=60sn	386	145	37.56	21	5.44	262	% 43
STA=0.3sn LTA=30 sn	312	75	24.03	25	8.01	262	% 32.04

Tablo 4.3: SEISAN (Havskov ve Ottemoller, 1999) yazılımı içinde kullanılan CONDET programı içinde STA/LTA yönteminde seçilen parametre değerleri.

Parametre	Kullanılan Değer
Filtre	2-20 Hz
Tetiklenme Oranı (STA/LTA)	5
Tetiklenme süresi (en az)	1 sn
Tetiklenme aralığı (en az)	20 sn
Tetiklenen istasyon sayısı (en az)	5
Tetiklenme öncesi zaman	30 sn
Kesme penceresi uzunluğu	300 sn

Tablo 4.4: 2019.01.01-2019.01.31 tarihleri arasında STA/LTA tarafından bulunan depremler.

No	DEPREM	ENLEM	BOYLAM	DERİNLİK	BÜYÜKLÜK	KATALOG	STA/LTA	MANUEL
1	20190101031100	-	-	-	-	-	+	
2	20190101081858	39.6052	26.0100	6.8	2.3	+	+	
3	20190102005100	-	-	-	-	-	-	+
4	20190102051833	40.0250	27.6480	7.6	2.0	+	+	
5	20190102183337	-	-	-	-	-	+	
6	20190103012141	-	-	-	-	-	+	
7	20190103022249	-	-	-	-	-	+	
8	20190103034154	38.8345	26.4545	10.7	2.2	+	+	
9	20190103034745	40.2703	27.2705	11.9	2.9	+	+	
10	20190103040419	38.8428	26.4368	7.4	2.4	+	+	
11	20190103072948	39.5502	27.0877	7.6	1.8	+	-	+
12	20190103125116	-	-	-	-	-	+	
13	20190103134315	40.7315	27.5560	23.2	2.0	+	+	
14	20190103162715	39.5097	26.1643	5.6	3.6	+	-	+
15	20190104084738	40.6010	28.9900	5.0	2.8	+	+	
16	20190104120937	41.07	28.67	7	2.1	+	+	
17	20190104230111	39.5772	25.9962	5.4	2.3	+	-	+
18	20190105041858	40.4447	28.3713	10.4	4.1	+	+	
19	20190105124141	40.78	27.42	7	2.1	+	+	
20	20190105163113	40.7485	27.3587	3.3	1.9	+	+	
21	20190105202900	38.7260	27.9262	5.3	2.6	+	+	
22	20190105233500	38.8900	26.4402	8.0	2.0	+	+	
23	20190106002116	40.7150	27.8188	10.2	1.7	+	+	
24	20190106081225	40.6157	27.7132	7.7	1.5	+	+	
25	20190106082525	39.6032	26.4628	5.4	1.6	+	+	
26	20190106092353	40.7580	25.7250	9.1	2.1	+	+	
27	20190106131255	-	-	-	-	-	+	
28	20190106133930	-	-	-	-	-	+	
29	20190106150449	38.8602	26.4357	7.9	2.3	+	-	+
30	20190106194200	38.8602	26.4357	7.9	2.3	+	-	+
31	20190106212240	-	-	-	-	+	+	
32	20190107014946	40.6167	28.9703	9.2	1.8	-	+	
33	20190107122900	-	-	-	-	-	+	
34	20190107141723	-	-	-	-	-	+	

Tablo 4.4 (devamı):

35	20190107171044	-	-	-	2.3	-	+	
36	20190107195320	38.86307	26.0208	6.1	3.3	+	-	+
37	20190107231000	38.4157	26.5865	16.3	2.3	+	+	
38	20190108035445	40.4015	27.4067	5.9	2.7	+	+	
39	20190108060052	38.8903	27.7480	5.2	-	+	+	
40	20190108100752	-	-	-	-	-	+	
41	20190108122821	-	-	-	2.4	-	+	
42	20190108205031	39.0288	26.2240	8.2	-	+	+	
43	20190108214441	-	-	-	1.8	-	+	
44	20190108224710	39.3713	26.0160	11.3	2.0	+	+	
45	20190109070020	40.8107	28.7587	23.3	2.3	+	-	+
46	20190109070900	40.6075	28.9912	5.1	2.3	+	+	
47	20190109075001	37.61	38.47	7	1.8	+	+	
48	20190109104600	37.3038	28.0722	10.0	4.2	+	+	
49	20190109113545	45.57	26.60	129	-	+	+	
50	20190109115626	-	-	-	-	-	+	
51	20190109120400	-	-	-	-	-	+	
52	20190109181022	-	-	-	2.3	-	+	
53	20190109181934	39.1610	26.0243	6.8	2.1	+	-	+
54	20190109184800	40.6027	28.9710	6.3	-	+	+	
55	20190109205600	-	-	-	2.6	-	+	
56	20190110063737	39.5103	26.1618	5.7	-	+	+	
57	20190110095800	-	-	-	2.4	-	+	
58	20190110215920	40.4043	27.4037	7.7	-	+	+	
59	20190110232635	-	-	-	2.8	-	+	
60	20190111010420	38.8693	27.7993	7.1	2.4	+	+	
61	20190111014338	38.89	27.82	6	3.5	+	+	
62	20190111015748	40.1550	25.0702	1.2	-	+	+	
63	20190111122935	-	-	-	2.5	-	+	
64	20190111123300	38.8638	27.7878	7.4	1.9	+	+	
65	20190111130256	40.5945	28.9642	8.5	2.2	+	-	+
66	20190111141800	40.60	28.96	13	3.9	+	+	
67	20190111160850	40.2818	28.8565	5.2	3.0	+	+	
67	20190111161929	38.8508	27.7773	4.3	-	+	+	
68	20190111183217	-	-	-	3.1	-	+	

Tablo 4.4 (devamı):

69	20190111192431	39.7722	25.6275	6.2	2.1	+	+	
70	20190111205424	37.70	37.41	7	2.7	+	+	
71	20190111225141	40.4488	28.3708	5.8	-	+	+	
72	20190111235029	-	-	-	-	-	+	
73	20190112001425	-	-	-	-	-	+	
74	20190112034300	-	-	-	-	-	+	
75	20190112185049	-	-	-	-	-	+	
76	20190112230152	-	-	-	1.7	-	+	
77	20190113011600	39.8103	26.3263	4.1	-	+	-	+
78	20190113013900	-	-	-	-	-	+	
79	20190113012335	-	-	-	-	-	+	
80	20190113092058	-	-	-	-	-	+	
81	20190113100814	-	-	-	-	-	+	
82	20190113105536	-	-	-	-	-	+	
83	20190113162136	-	-	-	-	-	+	
84	20190113174441	-	-	-	-	-	+	
85	20190113180100	-	-	-	2.0	-	+	
86	20190113203532	39.0928	26.0983	8.1	1.8	+	+	
87	20190113211345	40.6927	27.4455	12.0	2.3	+	+	
88	20190113233442	40.4545	26.3772	15.0	-	+	+	
89	20190114002514	-	-	-	-	-	+	
90	20190114002655	-	-	-	-	-	+	
91	20190114003321	-	-	-	-	-	+	
92	20190114013400	-	-	-	-	-	+	
93	20190114020047	-	-	-	-	-	+	
94	20190114035551	-	-	-	3.7	-	+	
95	20190114065839	39.36	25.61	3	3.3	+	+	
96	20190114071948	39.4155	25.5430	6.7	2.5	+	+	
97	20190114085725	38.8835	27.8048	8.3	2.1	+	+	
98	20190114090127	38.88	27.81	4	-	+	+	
99	20190114144100	-	-	-	3.5	-	-	+
100	20190114162319	37.9192	27.1213	6.8	-	+	+	
101	20190115011150	-	-	-	1.3	-	-	+
102	20190115001828	40.7642	27.4160	14.9	3.1	+	+	
103	20190115194125	39.06	27.78	5	-	+	+	

Tablo 4.4 (devamı):

104	20190116083000	-	-	-	-	-	-	+
105	20190116154320	-	-	-	-	-	+	
106	20190116165250	-	-	-	-	-	+	
107	20190116180400	-	-	-	2.4	-	+	
108	20190116200723	38.8763	26.1927	8.2	2.7	+	+	
109	20190116225235	38.7592	27.7795	11.6	-	+	+	
110	20190117031057	-	-	-	-	-	+	
111	20190117032211	-	-	-	-	-	+	
112	20190117035854	-	-	-	-	-	+	
113	20190117042756	-	-	-	-	-	+	
114	20190117055426	-	-	-	-	-	+	
115	20190117110052	-	-	-	1.8	-	+	
116	20190117115133	40.6772	27.4790	6.2	-	+	+	
117	20190117232652	-	-	-	-	-	+	
118	20190118011957	-	-	-	-	-	+	
119	20190118023542	-	-	-	-	-	+	
120	20190118035134	-	-	-	-	-	+	
121	20190118041756	-	-	-	2.9	-	+	
122	20190118111636	40.6957	27.4807	16.2	-	+	+	
123	20190118120116	-	-	-	2.2	-	+	
124	20190118132712	38.83	28.06	7	-	+	-	+
125	20190118133230	-	-	-	-	-	+	
126	20190118164420	-	-	-	-	-	+	
127	20190118182100	-	-	-	2.0	-	+	
128	20190118182535	40.74	29.00	12	-	+	+	
129	20190118184322	-	-	-	-	-	+	
130	20190118190245	-	-	-	-	-	+	
131	20190118190500	-	-	-	-	-	+	
132	20190118211258	-	-	-	-	-	-	+
133	20190118223900	-	-	-	-	-	+	
134	20190119014757	-	-	-	-	-	+	
135	20190119043200	-	-	-	-	-	+	
136	20190119043435	-	-	-	-	-	+	
137	20190119043938	-	-	-	-	-	+	
138	20190119052200	-	-	-	2.4	-	+	

Tablo 4.4 (devam):

139	20190119052338	40.7650	28.9893	5.4	-	+	+	
140	20190119074443	-	-	-	-	-	+	
141	20190119075413	-	-	-	-	-	+	
142	20190119090410	-	-	-	-	-	+	
143	20190119123139	-	-	-	1.3	-	+	
144	20190119180726	27.4766	40.6566	7.0	-	-	+	
145	20190119183826	-	-	-	-	-	+	
146	20190119220052	-	-	-	1.3	-	+	
147	20190120043949	40.6917	27.4610	13.1	-	+	+	
148	20190120061739	-	-	-	-	-	+	
149	20190120103019	-	-	-	2.1	-	+	
150	20190120142100	39.2465	28.3432	2.3	-	+	-	+
151	20190120153921	-	-	-	2.0	-	+	
152	20190120195611	39.8813	25.8570	13.0	1.3	+	+	
153	20190120211155	38.4035	28.5570	4.7	-	+	+	
154	20190120234315	-	-	-	-	-	+	
155	20190120234826	-	-	-	2.6	-	+	
156	20190121025846	39.1892	27.7698	8.3	2.3	+	+	
157	20190121031200	38.9468	26.2040	9.5	1.9	+	-	+
158	20190121064817	39.1443	29.0477	7.3	-	+	+	
159	20190121070335	-	-	-	-	-	+	
160	20190121085947	-	-	-	2.3	+	+	
161	20190121123900	39.4080	28.5015	4.2	-	+	-	+
162	20190121154736	-	-	-	2.6	-	+	
163	20190121180112	40.4568	28.1043	12.1	-	-	+	
164	20190122011538	-	-	-	2.8	+	+	
165	20190122012253	40.3837	28.3055	4.6	-	+	+	
166	20190122075021	-	-	-	-	-	+	
167	20190122085957	-	-	-	-	-	+	
168	20190122093816	-	-	-	1.8	+	+	
169	20190122180957	39.6998	27.8485	12.3	2.5	+	+	
170	20190123043717	39.8738	25.4977	6.2	2.2	+	+	
171	20190123064258	40.8213	27.9683	12.2	-	-	+	
172	20190123083013	-	-	-	-	-	+	
173	20190123120246	-	-	-	-	-	+	

Tablo 4.4 (devam):

174	20190123172500	-	-	-	2.8	-	+	
175	20190123191206	38.8932	27.8590	12.3	-	+	+	
176	20190124000421	-	-	-	-	-	-	+
177	20190124133317	-	-	-	2.9	-	+	
178	20190124140500	39.2757	29.2267	5.0	1.9	+	+	
179	20190124172617	40.6855	27.4667	11.3	-	+	+	
180	20190124221800	-	-	-	-	-	+	
181	20190125002320	-	-	-	3.1	-	+	
182	20190125042200	39.5990	28.0737	2.0	3.3	+	+	
183	20190125042929	39.4272	25.5483	9.6	1.6	+	+	
184	20190125044245	40.3872	26.9253	11.9	-	+	+	
185	20190125094541	-	-	-	4.4	-	+	
186	20190125201910	38.5823	27.1012	16.0	-	+	+	
187	20190126065314	-	-	-	-	-	+	
188	20190126135952	-	-	-	-	-	+	
189	20190126215000	-	-	-	1.6	-	+	
190	20190127000647	39.9623	28.0508	6.1	-	+	+	
191	20190127012100	-	-	-	2.0	-	+	
192	20190127022953	39.5792	26.0652	2.5	1.6	+	+	
193	20190127024030	40.6317	27.5488	24.2	-	+	+	
194	20190127031225	-	-	-	4.3	-	+	
195	20190127031442	39.0222	27.7567	12.8	4.0	+	+	
196	20190127031500	38.5815	27.0938	7.0	-	+	+	
197	20190127031558	-	-	-	-	-	+	
198	20190127042200	-	-	-	2.0	-	+	
199	20190127045643	39.0347	27.7767	7.5	2.5	+	+	
200	20190127085947	38.9793	26.4272	12.5	-	+	+	
201	20190127101600	-	-	-	2.2	-	+	
202	20190127120140	38.8457	26.4255	7.5	1.5	+	+	
203	20190127123400	39.8288	27.9590	14.1	1.2	+	+	
204	20190127170428	41.6353	26.5293	6.1	-	+	+	
205	20190127175000	-	-	-	2.0	-	+	
206	20190127192100	39.5355	25.9977	6.1	-	+	-	+
207	20190127204229	-	-	-	2.1	-	+	
208	20190127210300	39.0403	27.7818	7.3	-	+	-	+

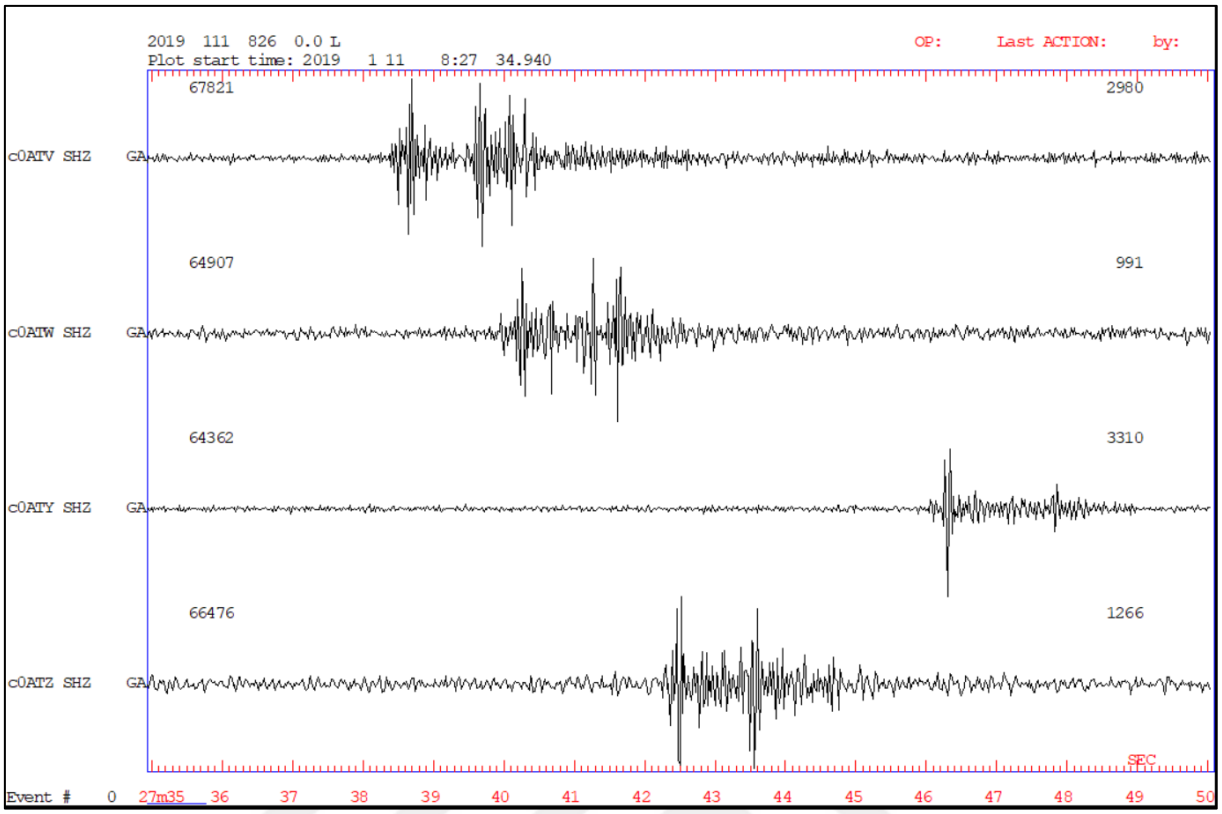
Tablo 4.4 (devam):

209	20190127221800	-	-	-	2.3	-	+	
210	20190128074933	39.4797	26.1380	5.5	1.5	+	+	
211	20190128082100	39.4093	26.2298	12.0	-	+	-	+
212	20190128082420	-	-	-	-	-	+	
213	20190128083011	-	-	-	-	-	+	
214	20190128094157	-	-	-	-	-	+	
215	20190128133756	-	-	-	3.5	-	+	
216	20190128165733	39.4410	26.1915	5.3	-	+	+	
217	20190128171400	-	-	-	2.0	-	-	+
218	20190128175225	39.4412	26.1595	5.1	1.9	+	+	
219	20190128180020	39.4633	26.0745	1.9	1.8	+	+	
220	20190128182349	39.4452	26.0948	5.0	2.3	+	+	
221	20190128184417	39.4092	27.8683	8.4	1.9	+	+	
222	20190128195816	39.6122	26.4350	5.9	-	+	+	
223	20190128213918	-	-	-	2.4	-	+	
224	20190129005822	39.4222	25.9740	9.2	2.2	+	+	
225	201901290147	39.4827	26.1222	8.0	-	+	+	
226	20190129021255	-	-	-	-	-	+	
227	20190129023152	-	-	-	-	-	+	
228	201901290253	-	-	-	-	-	+	
229	20190129105827	-	-	-	-	-	+	
230	20190129174734	-	-	-	-	-	-	+
231	20190129181727	-	-	-	-	-	+	
232	20190129181853	-	-	-	2.2	-	+	
233	20190129201841	39.5582	26.1753	6.3	-	+	+	
234	201901292321	-	-	-	-	-	+	
235	20190129234939	-	-	-	2.3	-	+	
236	20190129235855	39.4507	26.1538	8.1	2.1	+	+	
237	201901300153	39.7838	27.9068	5.4	2.5	+	+	
238	20190130020435	39.5312	26.1748	7.7	-	+	+	
239	20190130035958	-	-	-	1.5	-	+	
240	20190130040830	40.3633	28.6313	13.0	-	+	+	
241	20190130050614	-	-	-	1.5	-	+	
242	20190130111114	40.4530	26.9358	9.9	2.2	+	+	
243	20190130124732	39.1353	27.0223	8.3	-	+	-	+

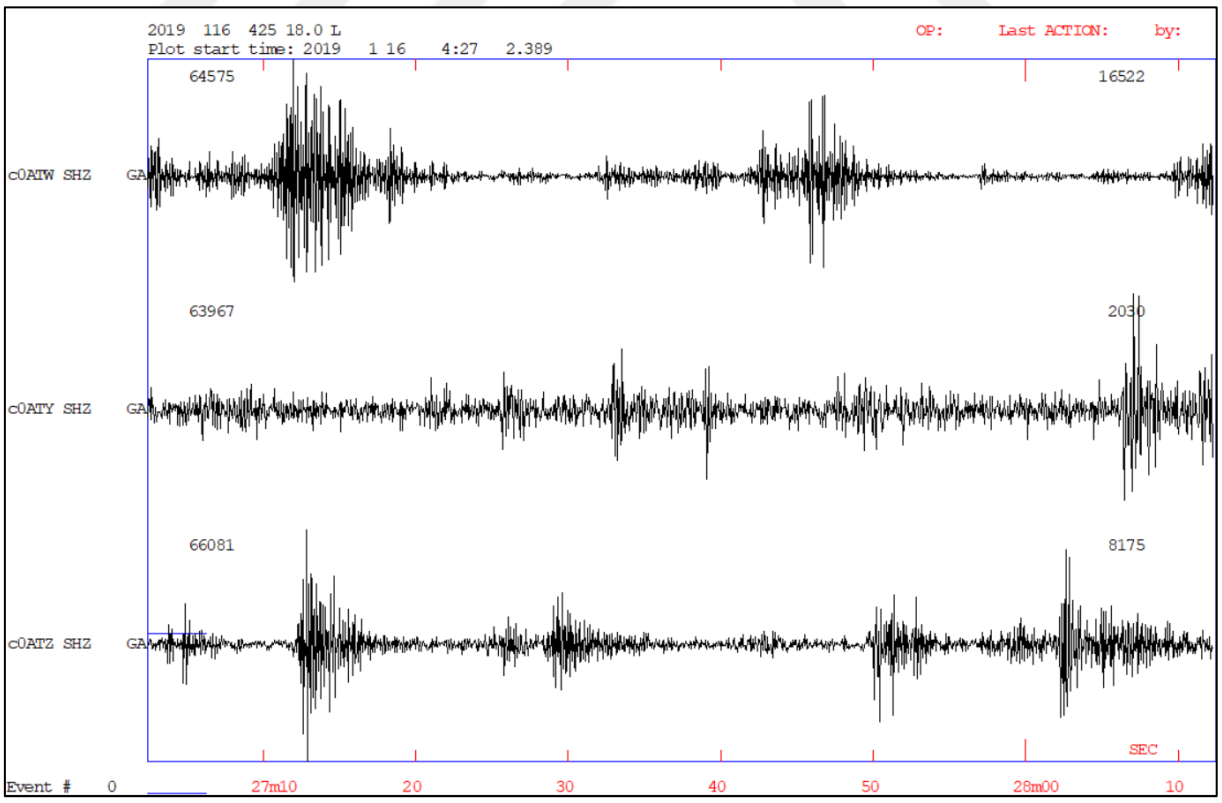
Tablo 4.4 (devam):

244	20190130132031	-	-	-	1.9	-	+	
245	20190130145512	39.5853	26.1198	6.8	-	+	+	
246	20190130162321	-	-	-	2.8	-	+	
247	20190130165545	45.20	26.49	132	-	+	+	
248	20190130171457	-	-	-	-	-	+	
249	20190130184353	-	-	-	1.6	-	+	
250	20190130193100	40.8748	25.6765	6.1	-	+	+	
251	20190130202900	-	-	-	-	+	+	
252	20190130224340	-	-	-	-	-	+	
253	20190131044644	-	-	-	-	-	-	+
254	20190131051245	-	-	-	2.8	-	+	
255	20190131091059	39.1722	26.0325	13.2	-	+	+	
256	20190131112411	-	-	-	-	-	+	
257	20190131131341	-	-	-	-	-	+	
258	20190131132120	-	-	-	-	-	+	
259	20190131144953	-	-	-	1.9	-	+	
260	20190131173423	40.7113	27.4447	8.5	-	+	+	
261	20190131181228	-	-	-	1.9	-	+	
262	20190131203700	40.0352	27.4357	95		+	+	

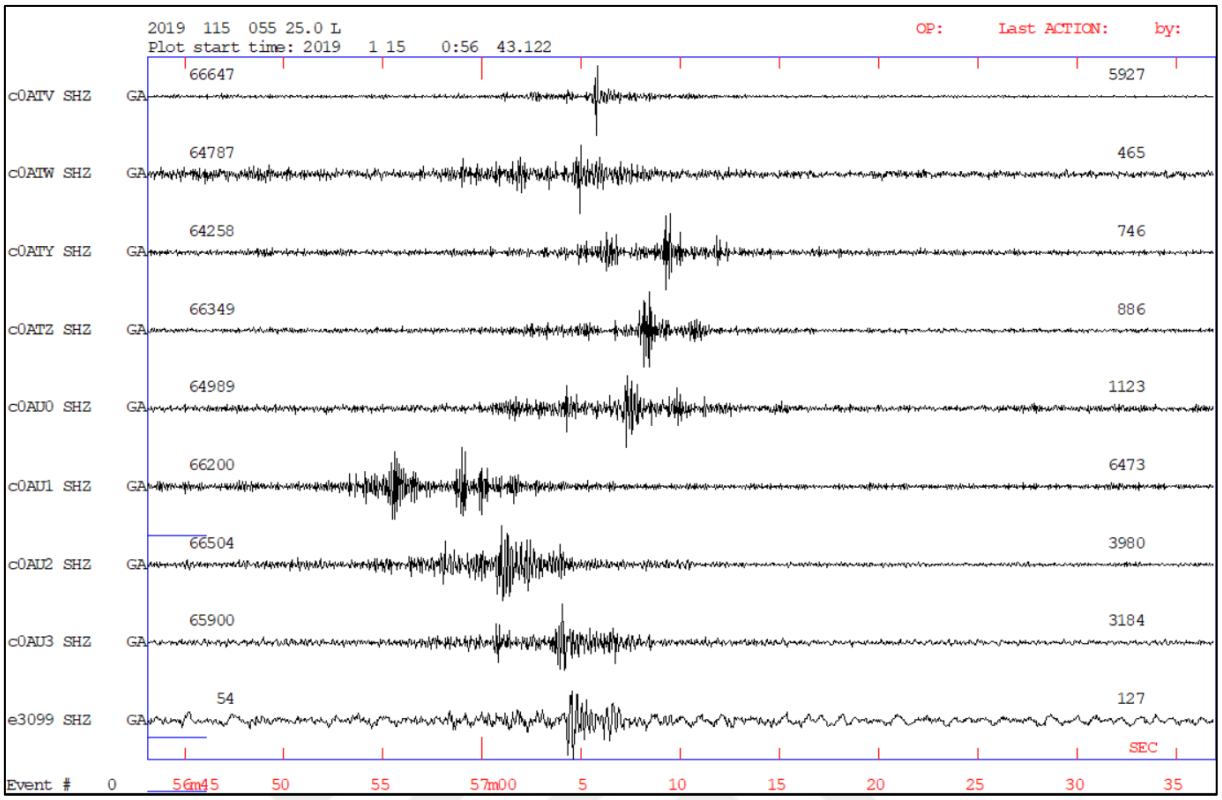
Tablo 4.2'de ilk satırdaki hata yüzdesinin yüksek olmasına neden olan hatalı deprem örneklerinden birkaçı Şekil 4.2, 4.3 ve 4.4'te verilmektedir. STA/LTA yöntemi kullanılarak hatalı tespit edilen olaylardan önemli bir kısmı deprem olmayan (patlatma veya yüksek enerjiye sahip endüstriyel faaliyetler) kayıt formlarıdır. Diğer hatalı keşif nedenleri arasında; uzun süreli depremlerde ikinci bir tetiklenme (P ve S tetiklenmeleri), farklı frekans aralıklarında çevresel gürültülerin sinyal enerjisini gölgelemesi, mevsimsel ve hava şartları nedeniyle ortaya çıkan enerji formları sayılabilir. Şekil 4.2'de bir patlatma kaydı örneği verilmektedir. Yüksek enerjili bu dalga formları özellikle yakın istasyon ağlarında yeterli sayıda istasyonu tetikleyerek bir olay olarak listelenir. Şekil 4.3 ve Şekil 4.4'te çevresel gürültülerden kaynaklı olarak istasyonlar tarafından kaydedilen bir kayıt örneği verilmektedir. Bu tip hatalı keşifler ancak tecrübeli bir operatörün manuel kontrolü sırasında farkedilebilmektedir. Eğer kayıt formları deprem dalga formlarıyla çok benzer ise, manuel kontrol ötesinde farklı veri analiz yöntemleri (örneğin spektral içerikler) devreye alınması gerekecektir.



Şekil 4.2: STA/LTA tarafından algılanan bir patlatma kaydı örneği.

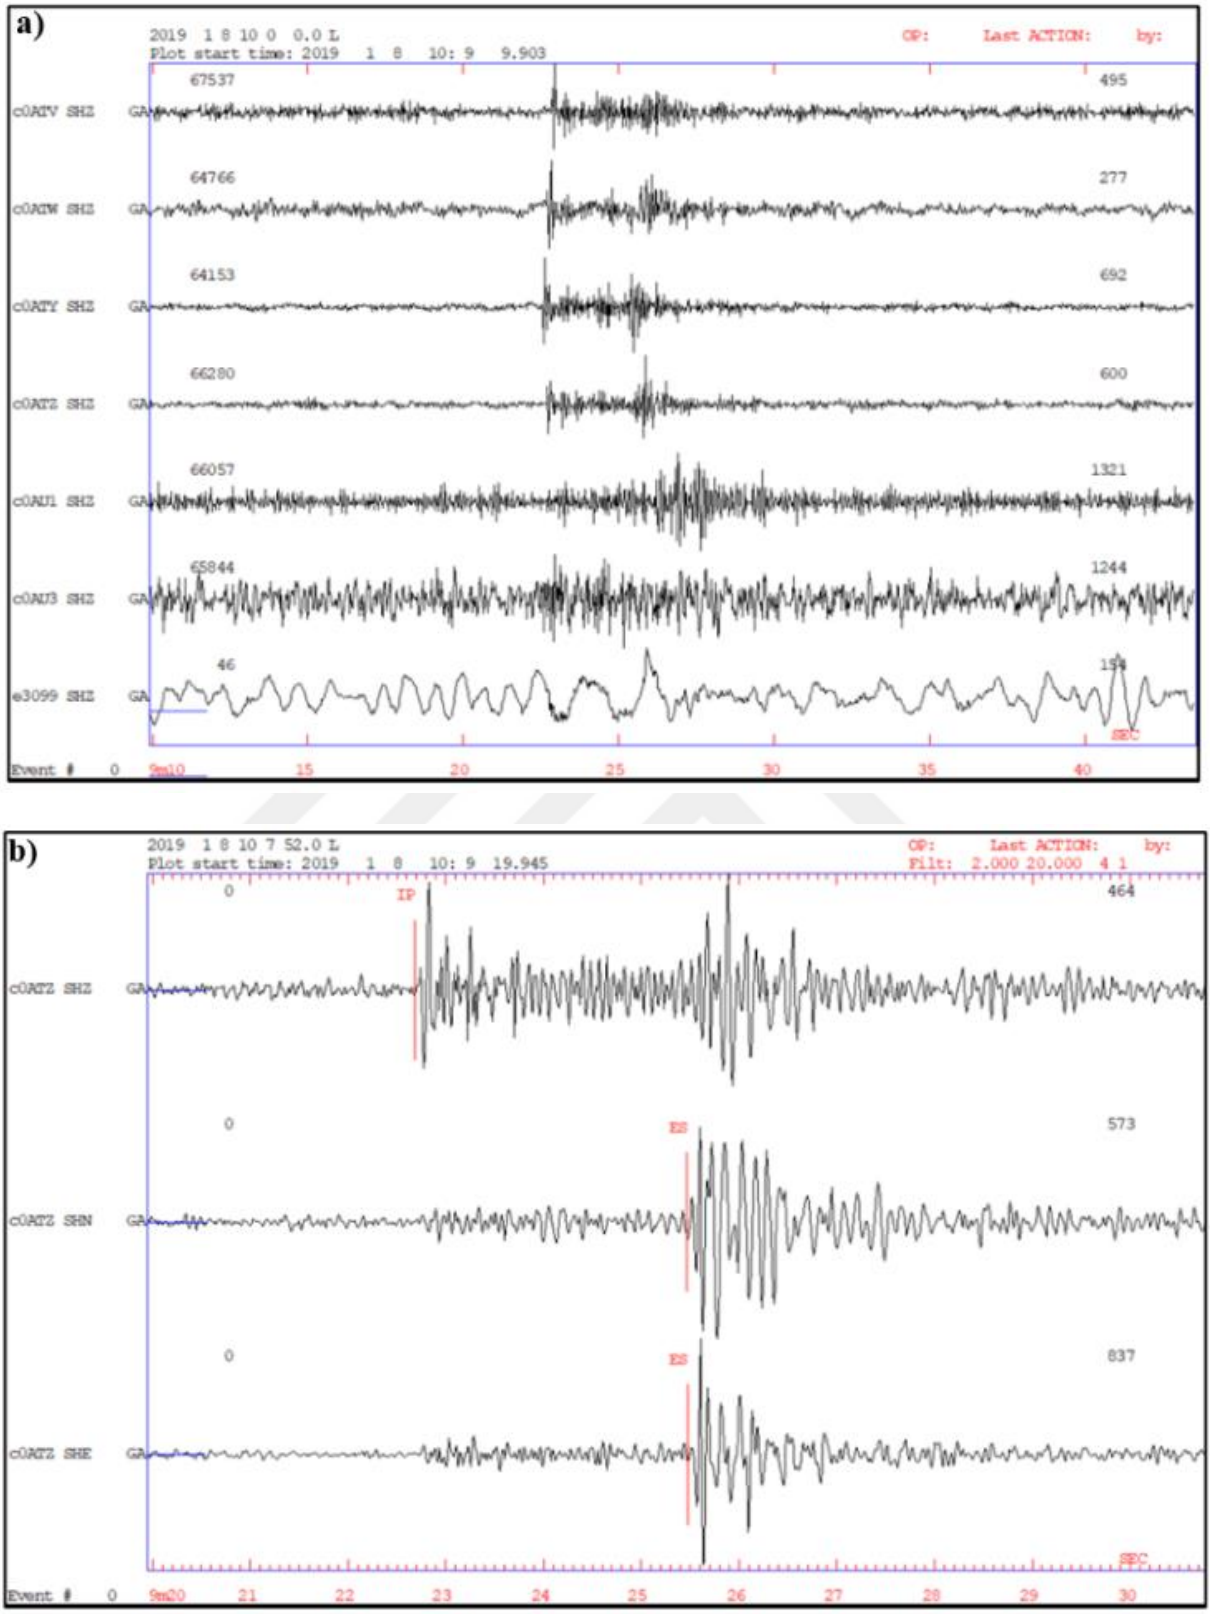


Şekil 4.3: Çevresel gürültülerden kaynaklı olarak istasyonlar tarafından kaydedilen bir kayıt örneği.

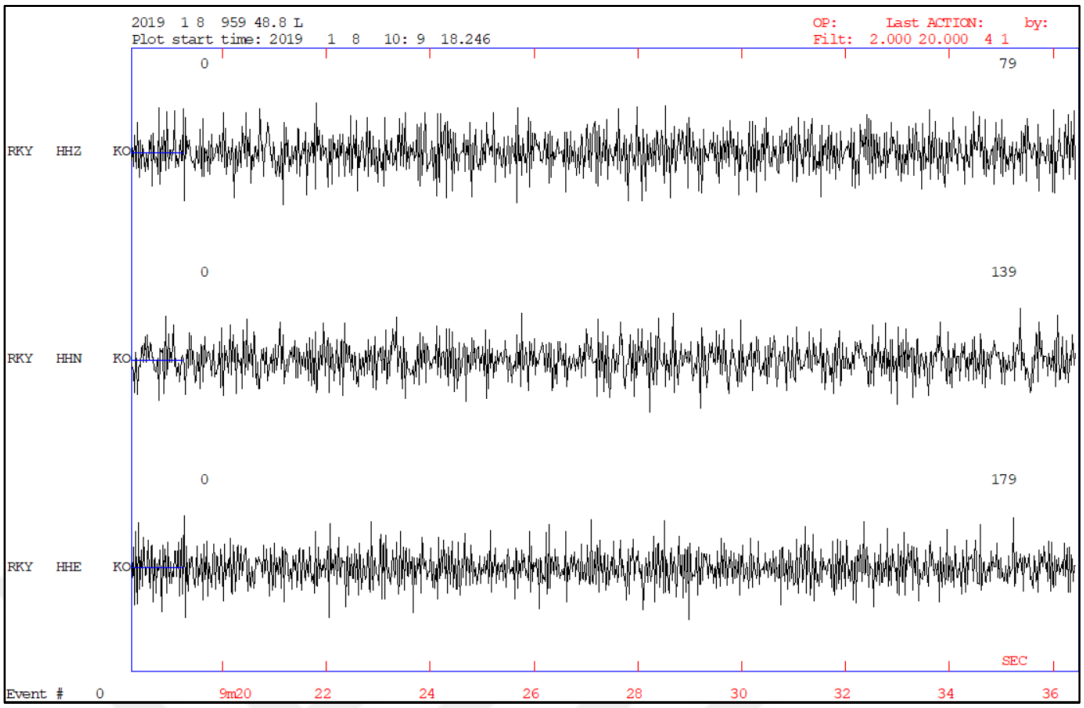


Şekil 4.4: Çevresel gürültülerden kaynaklı olarak istasyonlar tarafından kaydedilen bir kayıt örneği.

Aşağıdaki şekillerde kataloglarda bulunamayan ancak MONGAN ağı tarafından tespit edilen depremlerden örnekler verilmiştir. Şekil 4.5'te 2019.01.08 tarihinde saat 10:09:22.7'de MONGAN istasyonları tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları ve depremin c0ATZ istasyonunda üç bileşen deprem kaydı üzerinde P, S faz işaretlemeleri verilmiştir. Depremin P ve S dalga varışları arasındaki zaman farkı t_s- t_p= 25.5-22.7=2.8 sn'dir. Depremin istasyonlara olan uzaklığı ise yaklaşık olarak D=(t_s- t_p)*8=22,4 km'dir. Ulusal kataloglarda yapılan taramada bu depremin yer almadığı görülmüştür (Tablo 4.4). Örnek olarak MONGAN sismik kayıtçılarına yaklaşık 11 km uzaklıkta bulunan Kandilli rasathanesine ait RKY deprem istasyonu kaydında depremin çevresel gürültü içinde kaldığı görülmektedir (Şekil 4.6). Yakın ve çok küçük genlikli bu deprem, STA/LTA analizinde sadece 5 istasyonda tetiklenme oranı olan 5 değerini aşabilmiş ve bir olay olarak sınıflanmıştır.

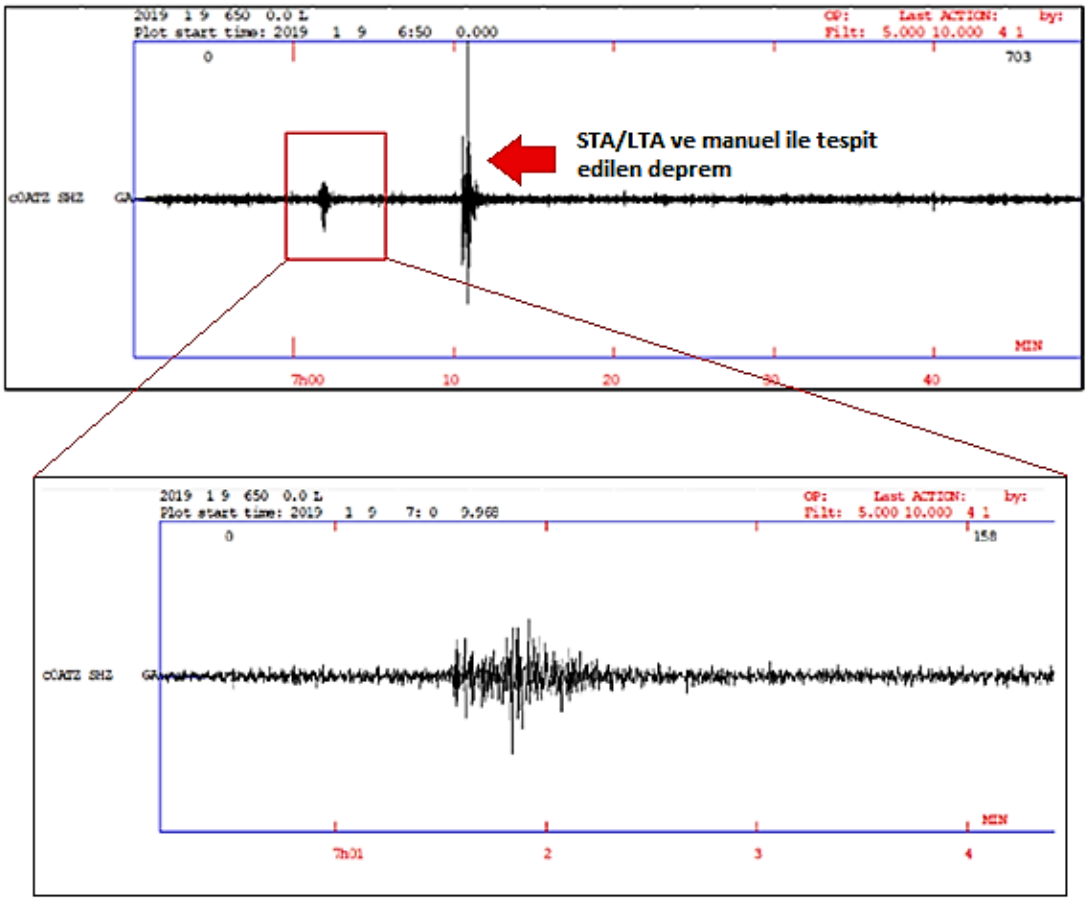


Şekil 4.5: a)2019.01.08 tarihinde saat 10:09:22.7'de istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b)c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S faz işaretlemesi.



Şekil 4.6: Kandilli Rasathanesi'ne ait 2019.01.08 tarihli saat 10:09:20 ait RKY istasyonu üç bileşen kaydı.

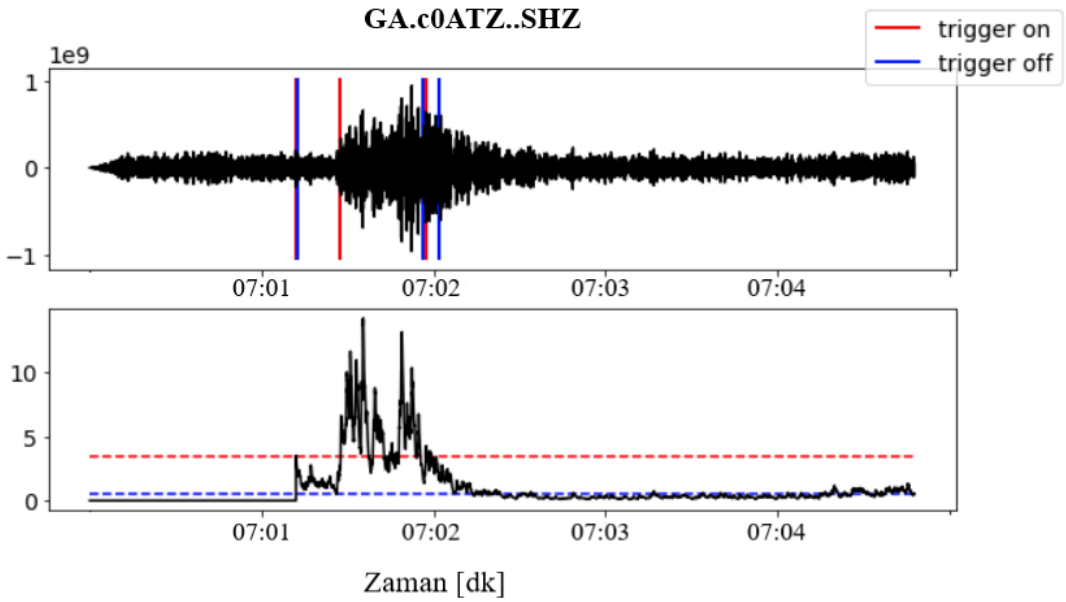
Şekil 4.7'de örnek bir istasyon kaydında sırasıyla manuel (kırmızı alan içinde) ve otomatik ayıklama ile keşfedilen iki ayrı deprem kaydı gösterilir. Şekil 4.7'de kırmızı kutu içinde gösterilen depremin STA/LTA tarafından tespit edilemediği belirlenmiştir. Tablo 4.5'te **CONDET** programına ait ana çıktılarından olan "**condet.out"** dosyasında tetiklenmenin sadece 4 istasyonda meydana geldiği görülmektedir. Ancak tetiklenme meydana gelmesi için en az 5 istasyonda tetiklenme oranının aşılması gerekmektedir. Şekil 4.8'de örnek olarak STA/LTA oranını aşan 4 istasyondan biri olan c0ATZ istasyonunun STA/LTA tetiklenme penceresi ve oran penceresi verilmektedir. Tetiklenme oranı 3 olarak alındığında 5 istasyonda tetiklenmenin meydana geldiği görülmüştür. Tablo 4.6'da tetiklenme oranının değiştirilmesi ile tetiklenmenin meydana geldiği istasyonlar, tetiklenme uzunluğu ve STA/LTA oranı verilmiştir. Şekil 4.9'da ise Tablo 4.6'da tetiklenen istasyonların STA/LTA grafikleri verilmiştir. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı göstermektedir.



Şekil 4.7: a) c0ATZ istasyonu düşey bileşen kaydı üzerinde otomatik ayıklama ve STA/LTA ile keşfedilen ve b) aynı kaydın kırmızı işaretli alanı içinde manuel keşfedilen ikinci olay.

Tablo 4.5: "**condet.out**" dosyasında verilen tetiklenen istasyonlar.

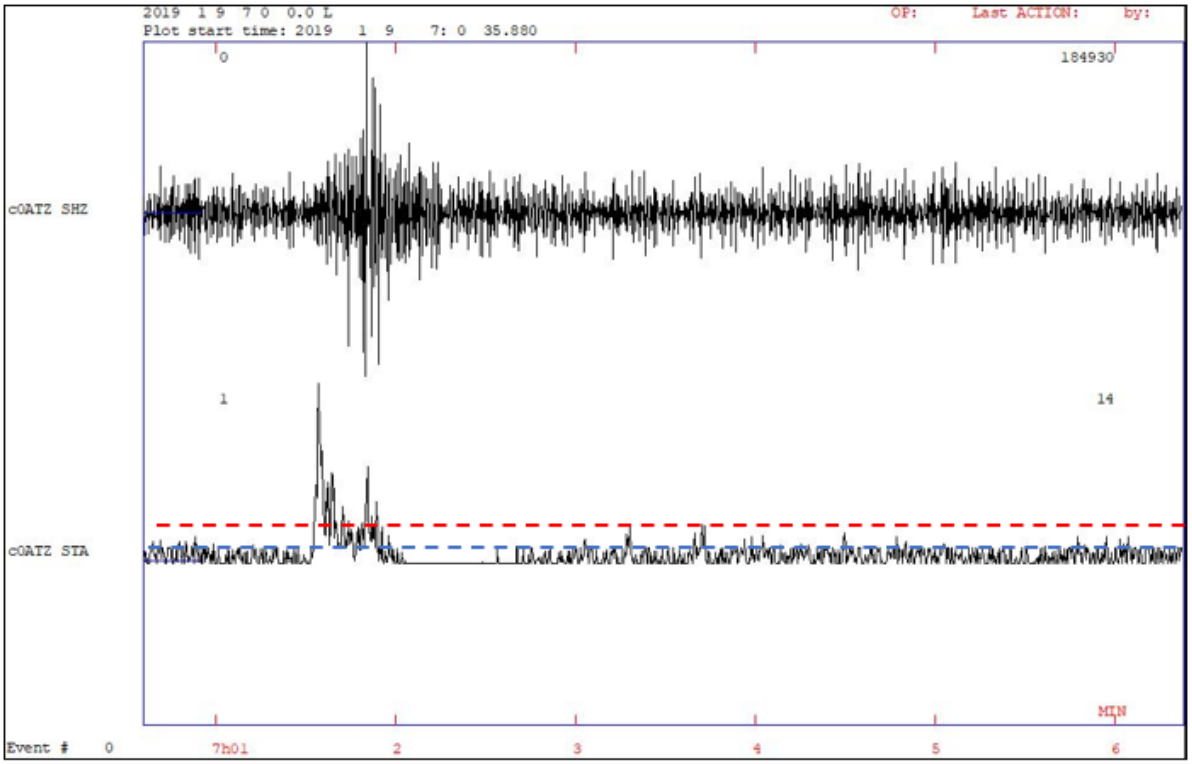
İstasyon	Bileşen	Deprem	Tetiklenme Uzunluğu	STA/LTA Oranı
c0ATY	SH Z	20190109070132	3.0	14.1
c0ATV	SH Z	20190109070133	2.5	13.2
c0ATZ	SH Z	20190109070133	3.1	15.6
c0AU1	SH Z	20190109070136	1.3	6.5

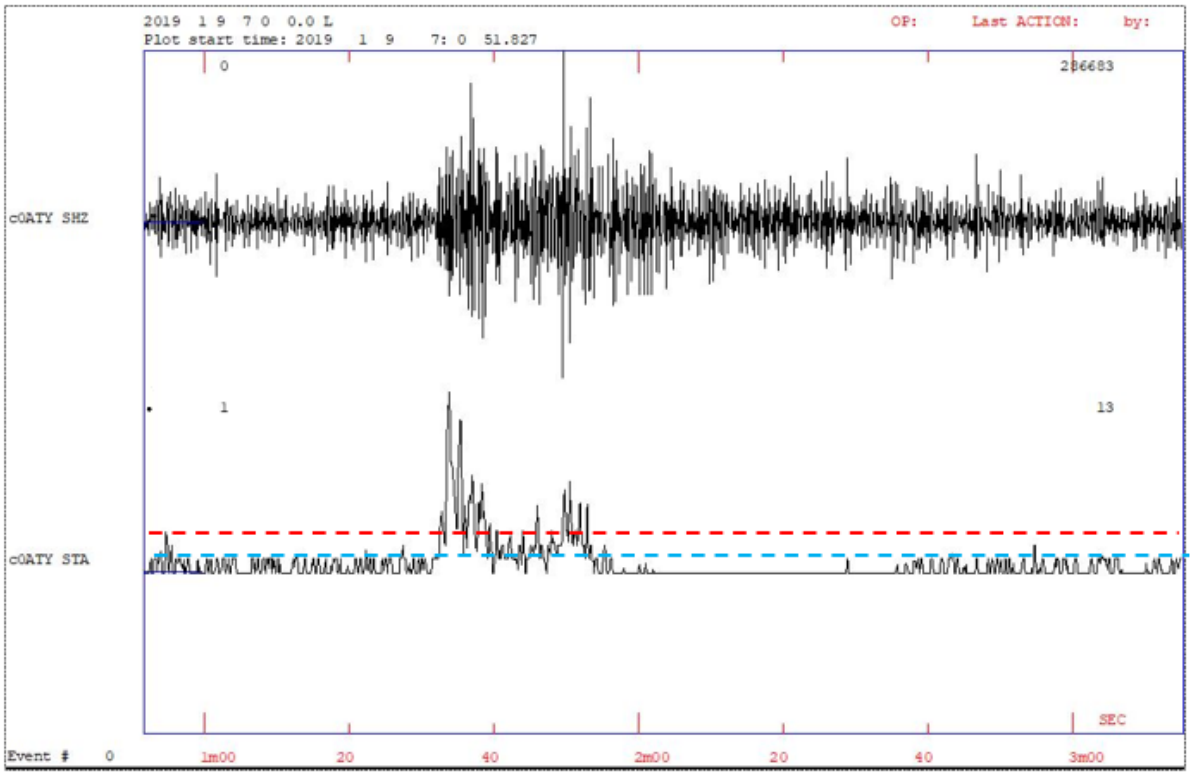


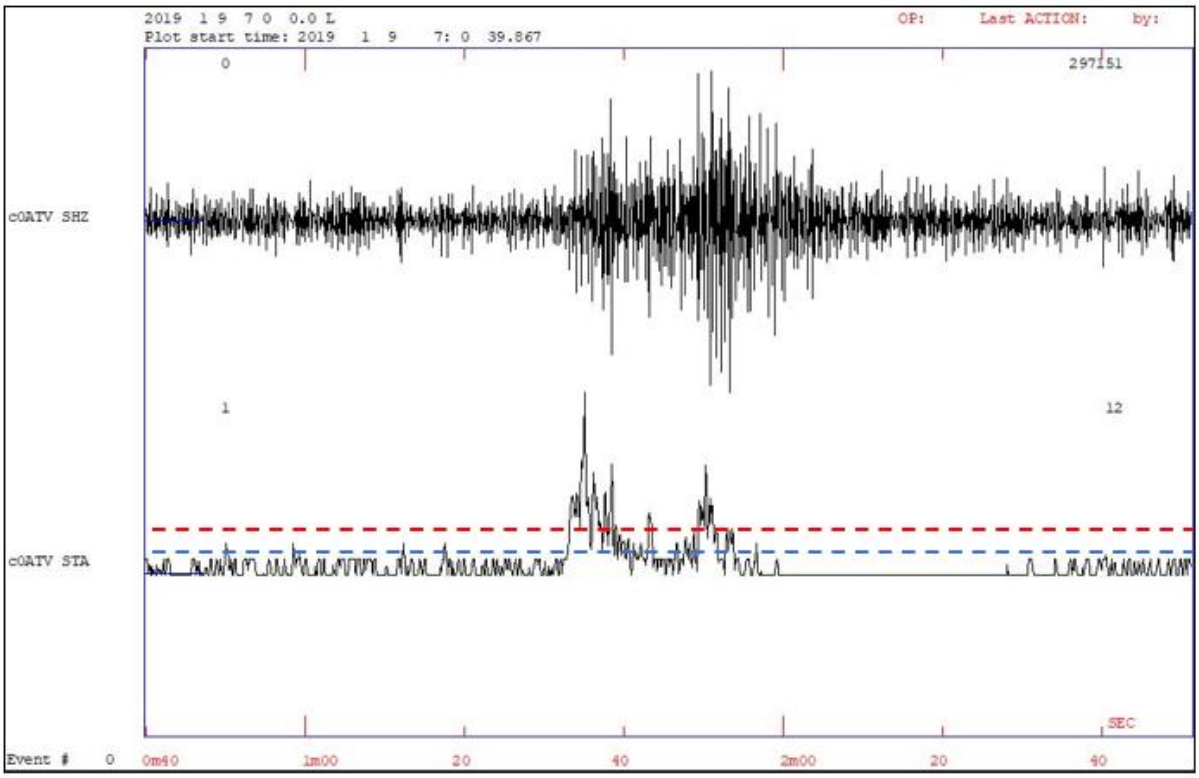
Şekil 4.8: a) 2019.01.09 tarihinde saat 07:00:00'da c0ATZ istasyonu tarafından kaydedilen depremin tetiklenme penceresi b) STA/LTA oran penceresi. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı gösterir.

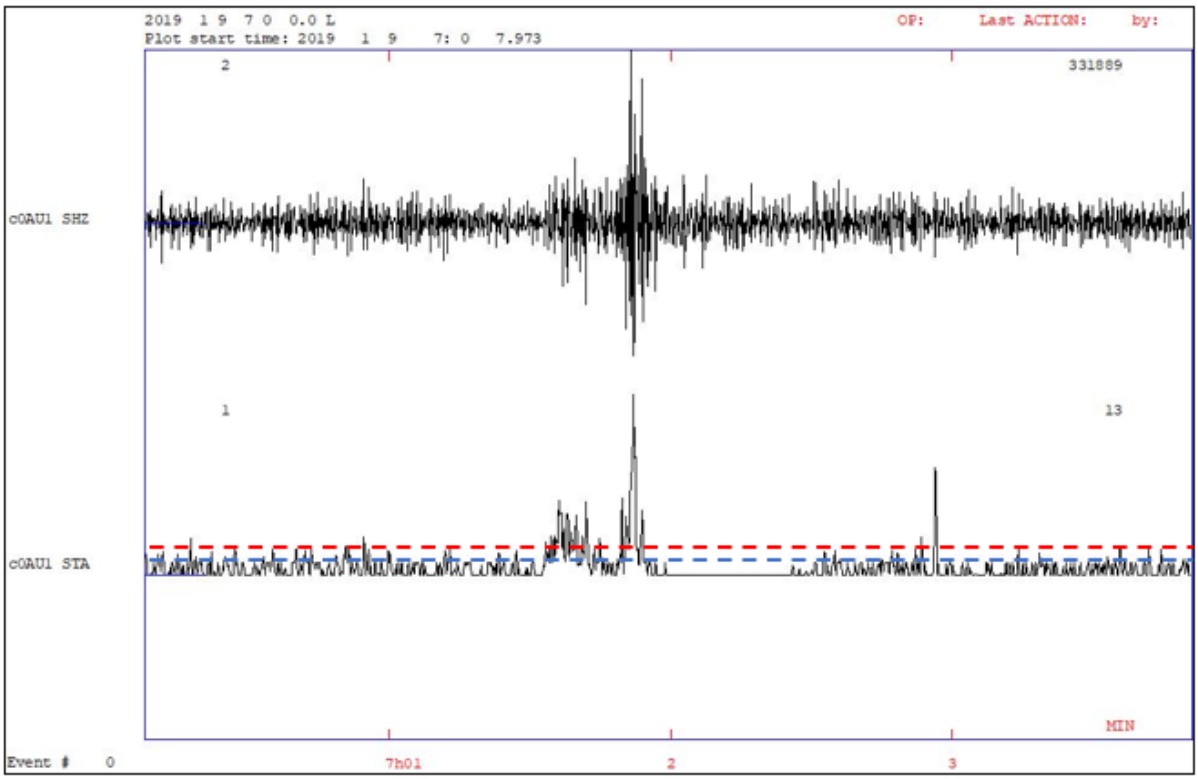
Tablo 4.6: 2019.01.09 tarihli deprem için tetiklenme oranı 3 olarak alındığında tetiklenme meydana gelen istasyonlar kırmızı kare ile işaretlenmiştir.

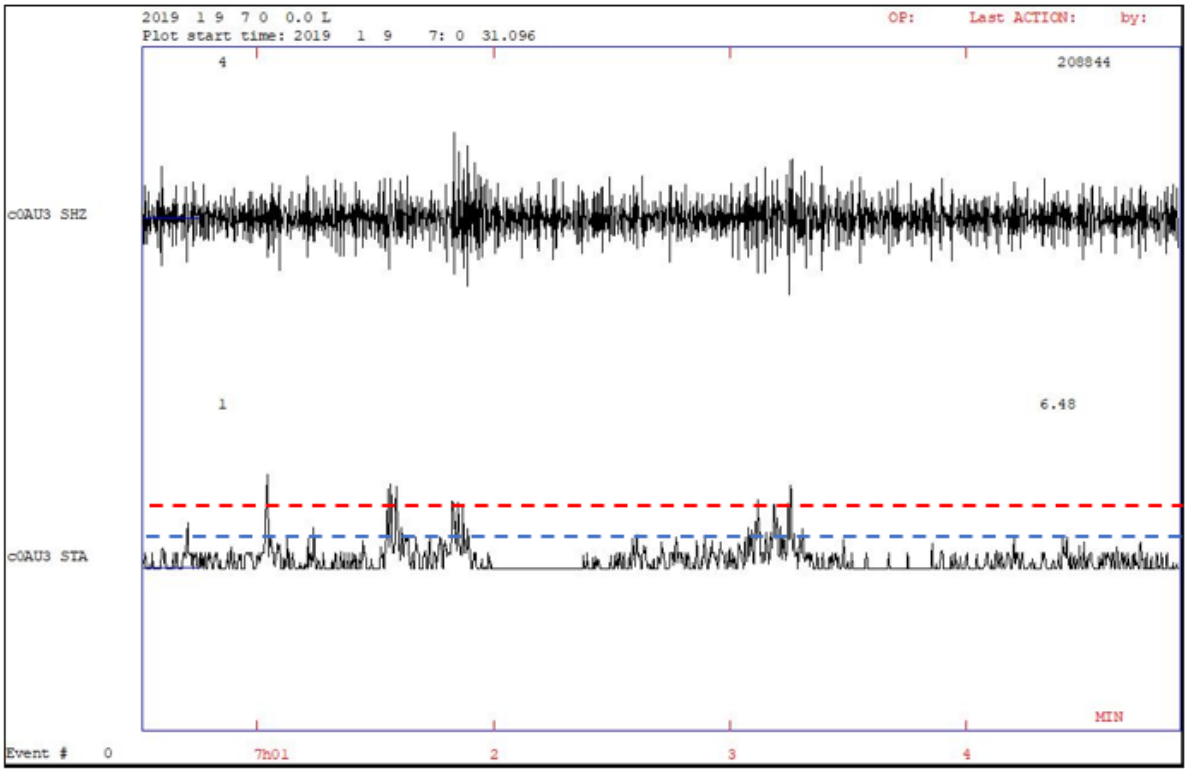
İstasyon	Deprem	Saat	Tetiklenme Uzunluğu	STA/LTA Oranı
c0ATW	2019/01/09	04:13:15	4.0	12.7
c0ATV	2019/01/09	04:13:15	6.4	12.8
c0ATZ	2019/01/09	04:13:17	1.7	5.3
c0AU3	2019/01/09	04:13:19	2.4	8.0
c0ATY	2019/01/09	04:13:19	3.0	9.0
----------	5	stations	----------	
c0ATZ	2019/01/09	07:01:32	3.6	15.6
c0ATY	2019/01/09	07:01:32	3.2	14.1
c0ATV	2019/01/09	07:01:33	2.7	13.2
c0AU1	2019/01/09	07:01:35	1.8	6.5
c0AU3	2019/01/09	07:01:35	1.0	7.6
----------	7	stations	----------	
c0ATY	2019/01/09	07:10:30	6.5	43.1
c0ATZ	2019/01/09	07:10:30	7.2	46.9
c0AU1	2019/01/09	07:10:31	4.8	38.6
c0ATW	2019/01/09	07:10:31	5.2	56.6
e3099	2019/01/09	07:10:31	3.1	25.8
c0ATV	2019/01/09	07:10:31	4.6	44.2
c0AU3	2019/01/09	07:10:31	3.5	45.5


2019 1 9 7 0 0.0 L
Plot start time: 2019 1 9 7: 0 35.880
OP: Last ACTION: by:
0
184930
c0ATZ SHZ
1
14
c0ATZ STA
MIN
Event # 0
7h01
2
3
4
5
6


2019 1 9 7 0 0.0 L
Plot start time: 2019 1 9 7: 0 51.827
OP: Last ACTION: by:
0
206683
c0ATY SHZ
1
13
c0ATY STA
SEC
Event # 0
1m00
20
40
2m00
20
40
3m00

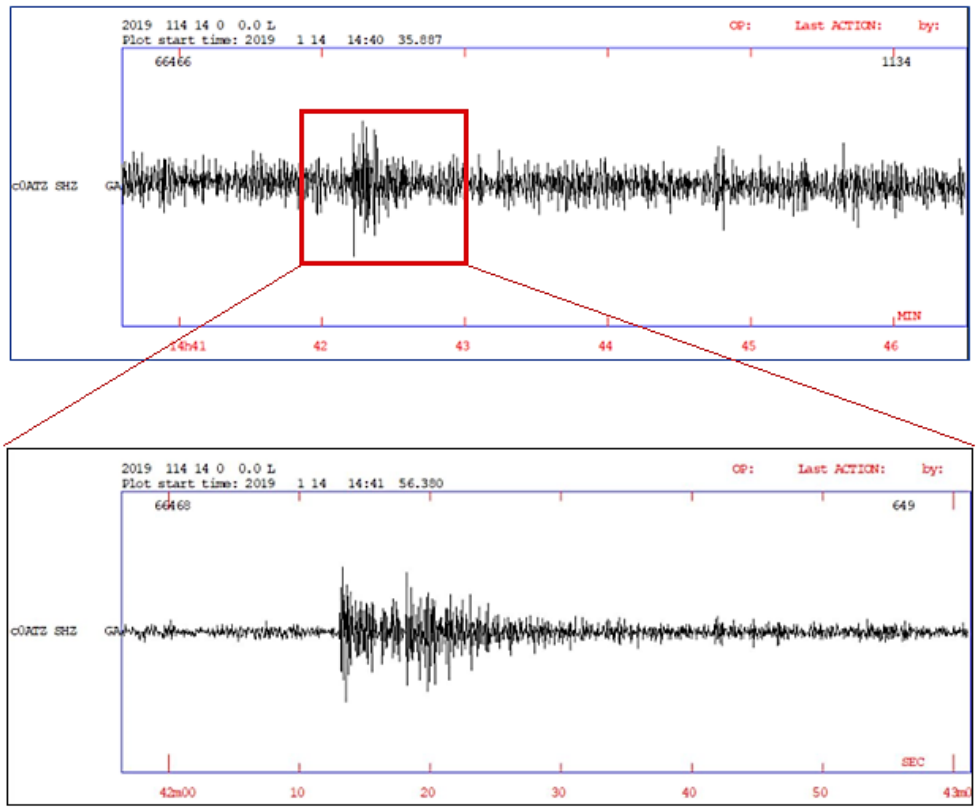

2019 1 9 7 0 0.0 L
Plot start time: 2019 1 9 7: 0 39.867
OP: Last ACTION: by:
0
297151
c0ATV SHZ
1
12
c0ATV STA
SEC
Event # 0
0m40
1m00
20
40
2m00
20
40


2019 1 9 7 0 0.0 L
Plot start time: 2019 1 9 7: 0 7.973
OP: Last ACTION: by:
2
331889
c0AU1 SHZ
1
13
c0AU1 STA
MIN
Event # 0
7h01
2
3

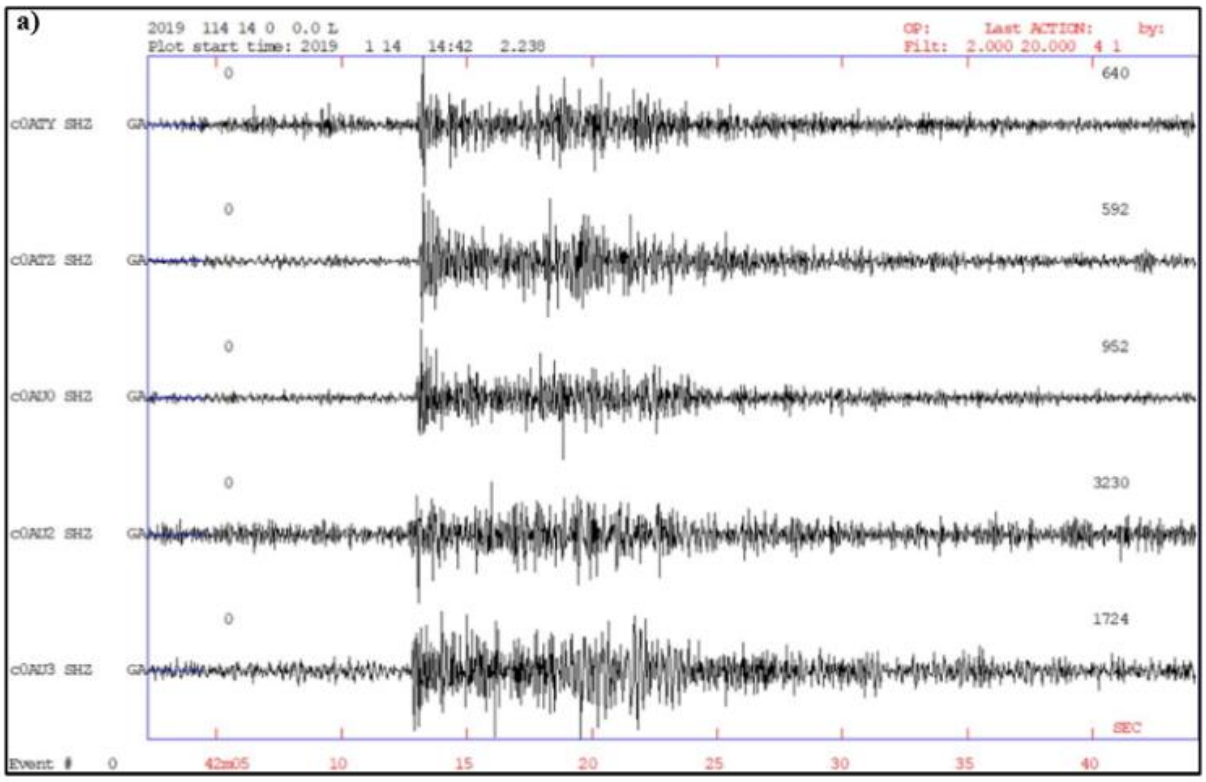


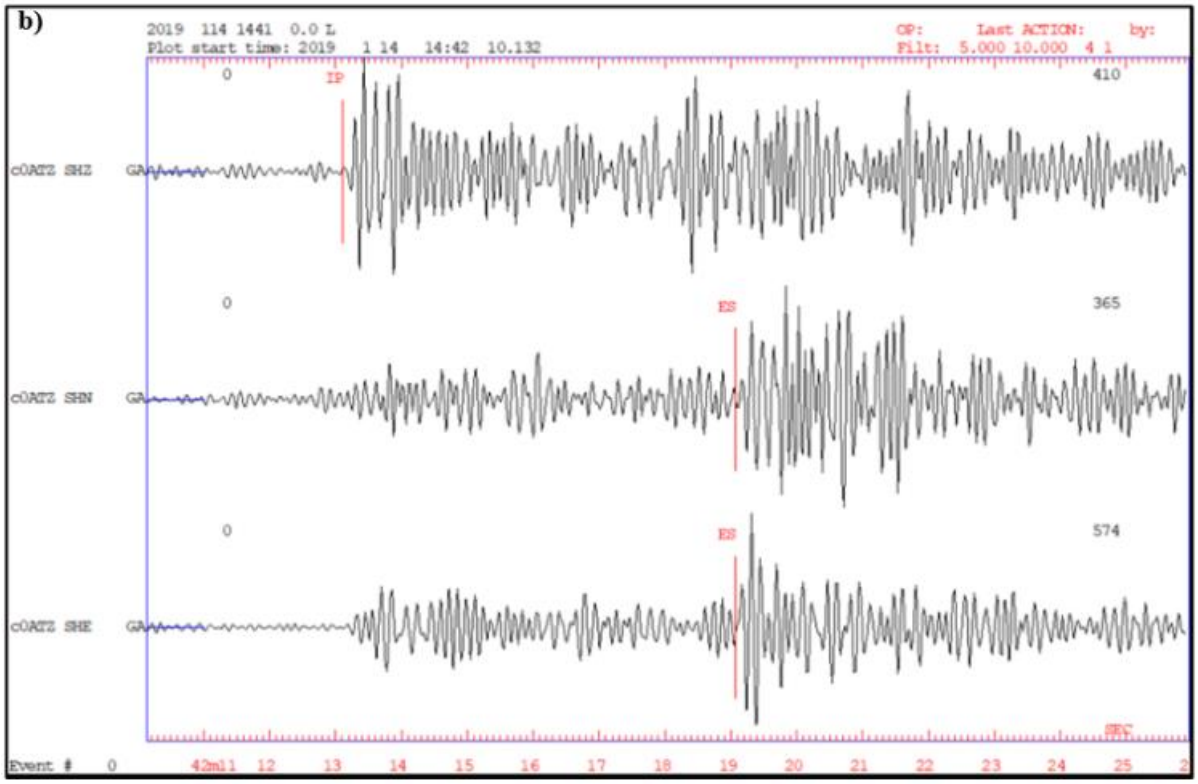
Şekil 4.9: Tablo 4.6'da verilen tetiklenen istasyonların STA/LTA grafikleri. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı göstermektedir.

Şekil 4.10'da c0ATZ istasyonu düşey bileşen kaydı üzerinde manuel olarak keşfedilen ancak Tablo 4.3'te verilen STA/LTA parametre değerleri ile tespit edilemeyen bir olay kaydı verilmektedir. Tablo 4.7'de tetiklenmenin sadece 4 istasyonda gerçekleştiği görülmektedir. Şekil 4.11'de depremin P ve S dalga varışları işaretlenmiştir. P ve S dalga varışları arasındaki zaman farkının t_s- t_p= 19-13=6 sn olduğu görülmektedir. Depremin istasyona olan uzaklığı ise D=(t_s- t_p)*8=48 km'dir. STA/LTA yönteminde kullanılan parametreler analizler kapsamında birçok kez test edilmiş ancak tetiklenme sadece 4 istasyonda gerçekleşmiştir. Tablo 4.2'de kullanılan istasyonlara e3754 istasyonu dahil edilerek bu depremin STA/LTA parametrelerinden filtre parametresinin 5- 15 Hz ve tetiklenme oranının 3 olarak seçilerek çalıştırılması ile tetiklendiği belirlenmiştir. Tablo 4.8'de tetiklenen istasyonlar verilmiştir. Şekil 4.12'de tetiklenen istasyonların STA/LTA grafikleri verilmiştir. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı göstermektedir.



Şekil 4.10: c0ATZ istasyonu düşey bileşen kaydı üzerinde manuel olarak keşfedilen ancak STA/LTA ile keşfedilemeyen olay kaydı.





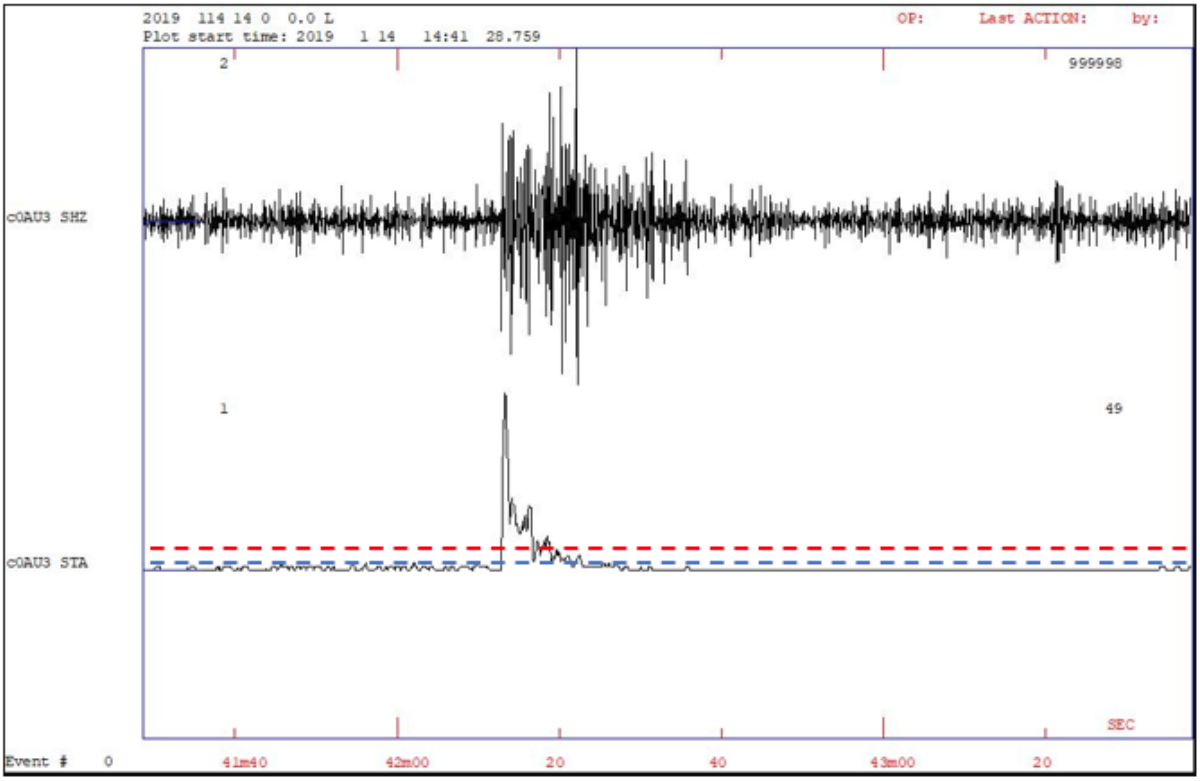
Şekil 4.11: a)2019.01.14 tarihinde saat 14:41:00'da istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b) c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S fazlarının işaretlenmesi.

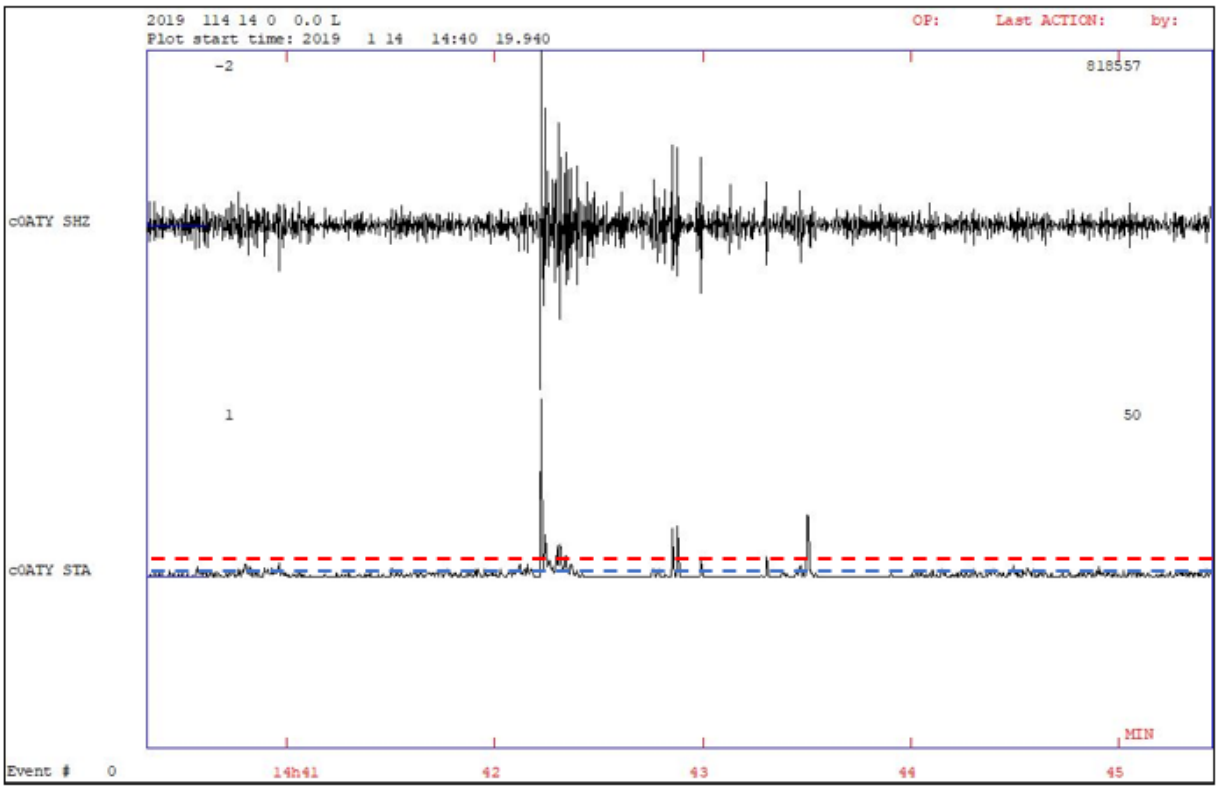
Tablo 4.7: "condet.out" dosyasında verilen tetiklenen istasyonlar.

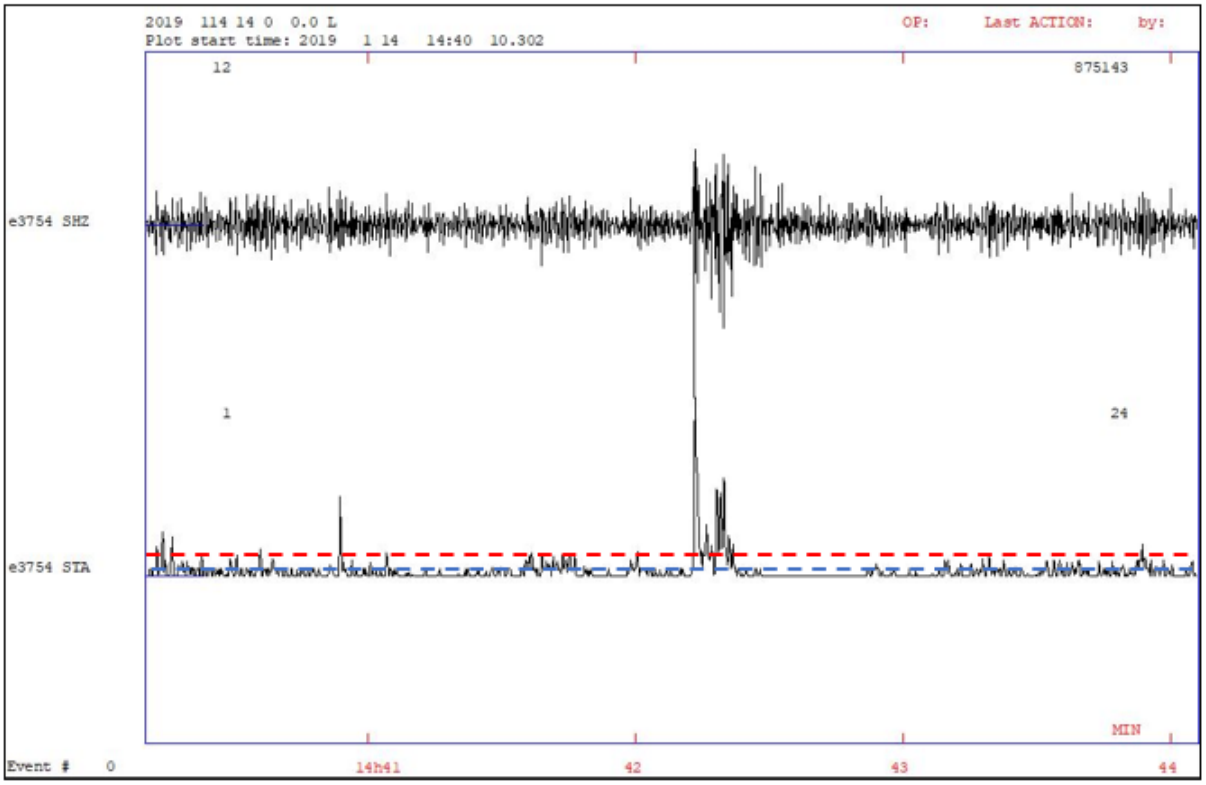
İstasyon	Bileşen	Deprem	Tetiklenme Uzunluğu	STA/LTA Oranı
c0ATY	SH Z	20190114144206	1.2	6.4
c0AU3	SH Z	20190114144212	3.7	39.8
c0AU0	SH Z	20190114144213	2.8	63.4
c0ATZ	SH Z	20190114144213	2.9	66.7

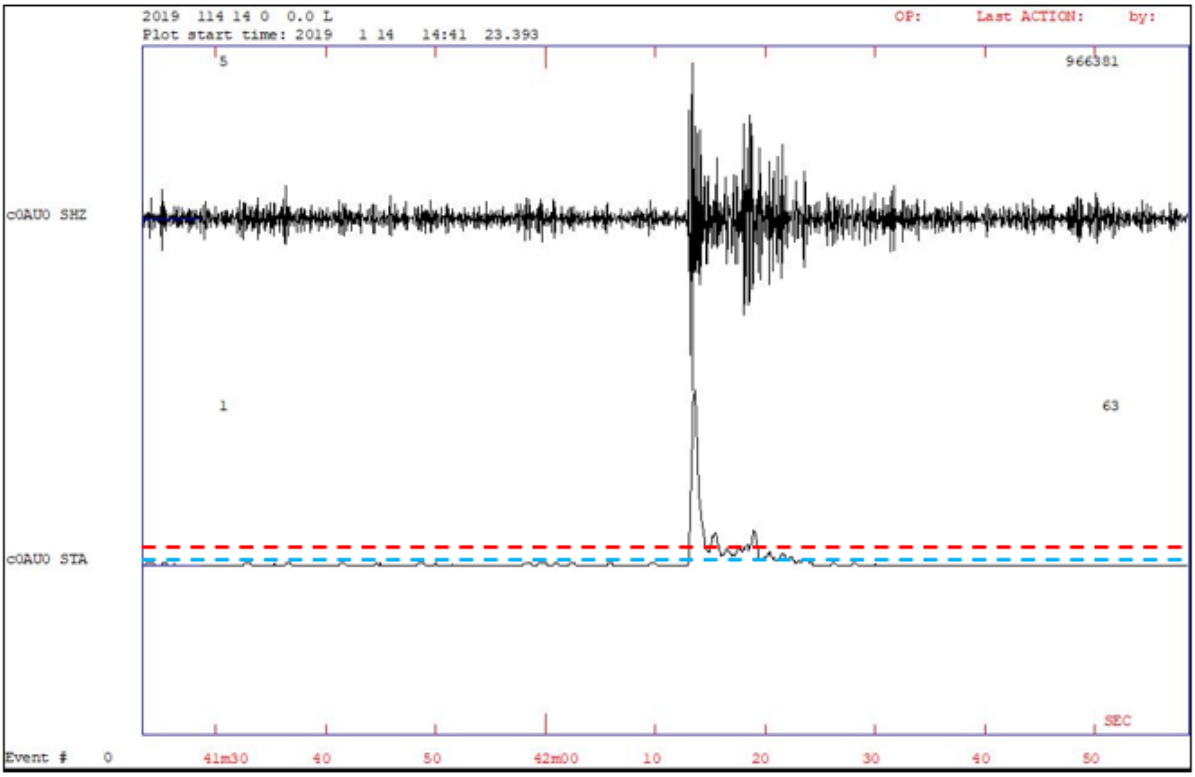
Tablo 4.8: Filtrenin 5-15 Hz ve tetiklenme oranının 3 seçilmesiyle **condet.out** dosyasında verilen tetiklenen istasyonlar.

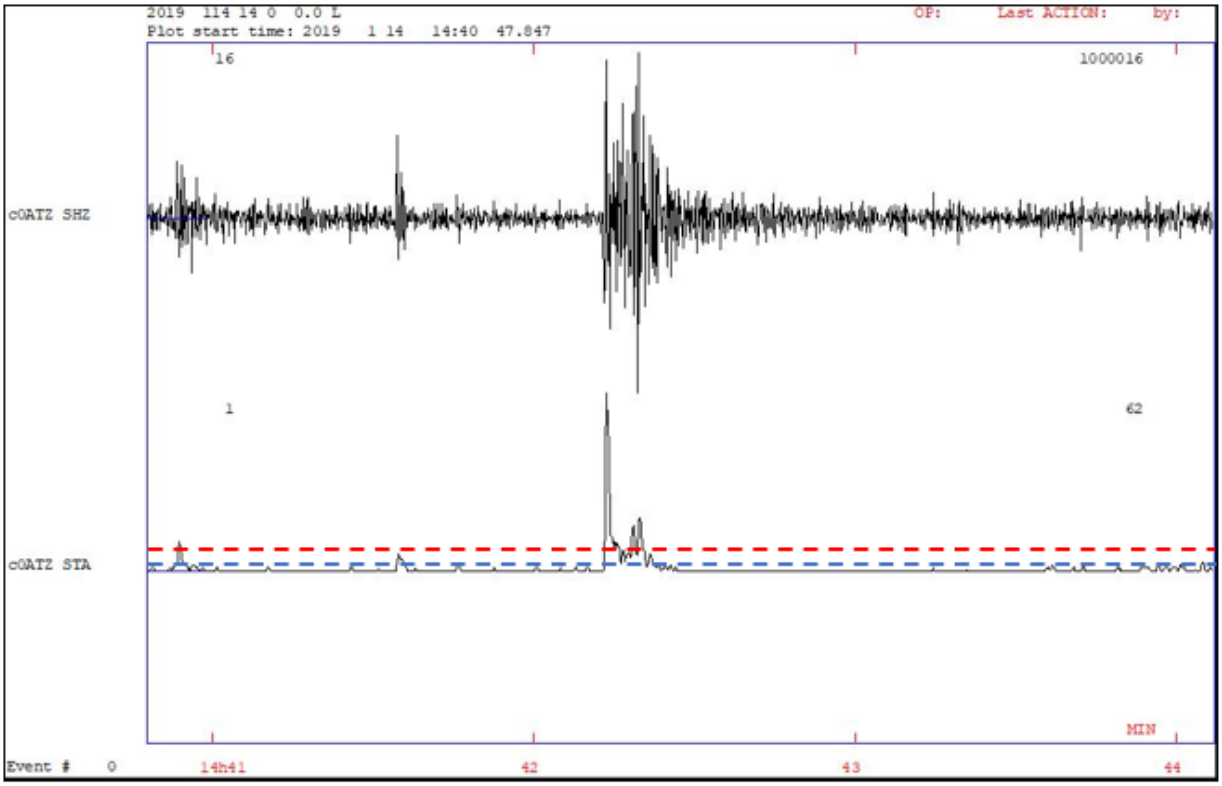
İstasyon	Deprem	Saat	Tetiklenme Uzunluğu	STA/LTA Oranı
c0AU3	2019/01/14	14:42:12	3.8	56.0
c0ATY	2019/01/14	14:42:13	1.1	62.7
e3754	2019/01/14	14:42:13	1.7	45.9
c0AU0	2019/01/14	14:42:13	2.8	54.5
c0ATZ	2019/01/14	14:42:13	2.9	63.0


2019 114 14 0 0.0 L
Plot start time: 2019 1 14 14:41 28.759
OP: Last ACTION: by:
2
999998
c0AU3 SHZ
1
49
c0AU3 STA
SEC
Event # 0
41m40
42m00
20
40
43m00
20


2019 114 14 0 0.0 L
Plot start time: 2019 1 14 14:40 19.940
OP: Last ACTION: by:
-2
818557
c0ATY SHZ
1
50
c0ATY STA
MIN
Event # 0
14h41
42
43
44
45


2019 114 14 0 0.0 L
Plot start time: 2019 1 14 14:40 10.302
OP: Last ACTION: by:
12
875143
e3754 SHZ
1
24
e3754 STA
MIN
Event # 0
14h41
42
43
44

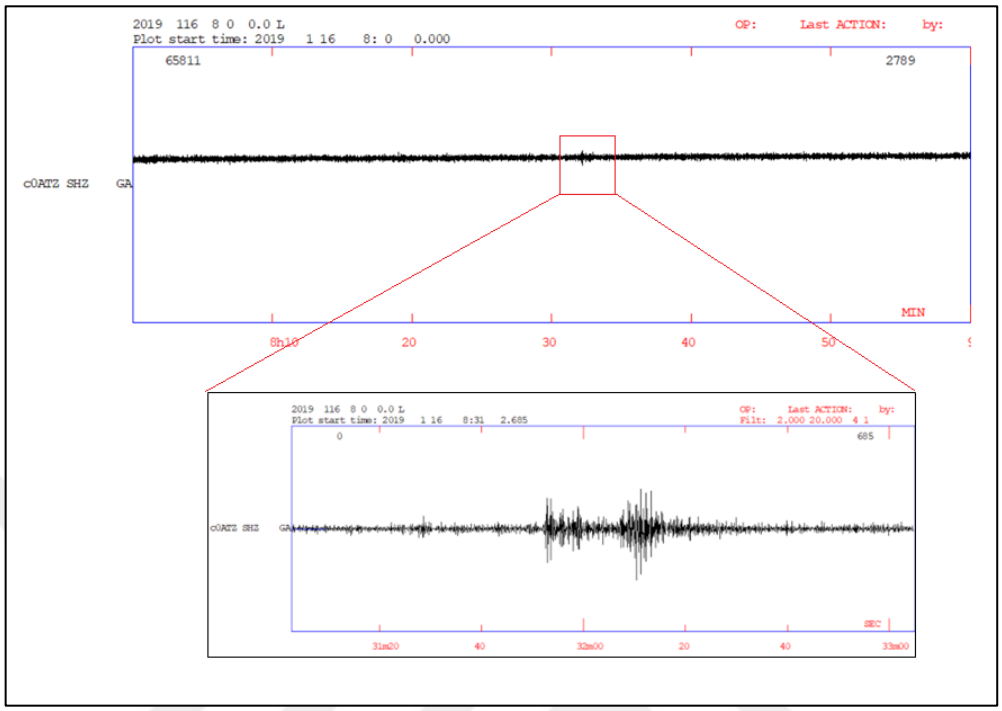

2019 114 14 0 0.0 L
Plot start time: 2019 1 14 14:41 23.393
OP: Last ACTION: by:
5
966381
c0AU0 SHZ
1
63
c0AU0 STA
SEC
Event # 0
41m30
40
50
42m00
10
20
30
40
50



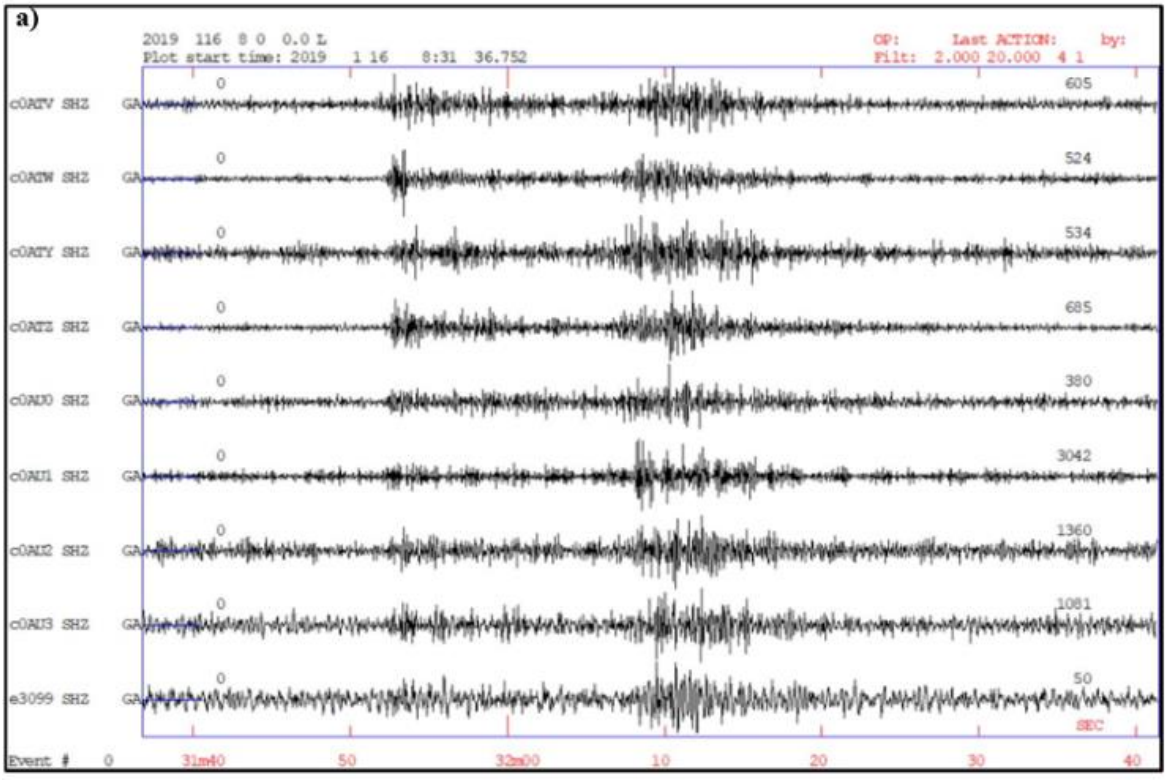
Şekil 4.12: Tablo 4.8'de verilen tetiklenen istasyonlar. Kesikli kırmızı çizgi STA/LTA oranının 3'ü aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı göstermektedir.

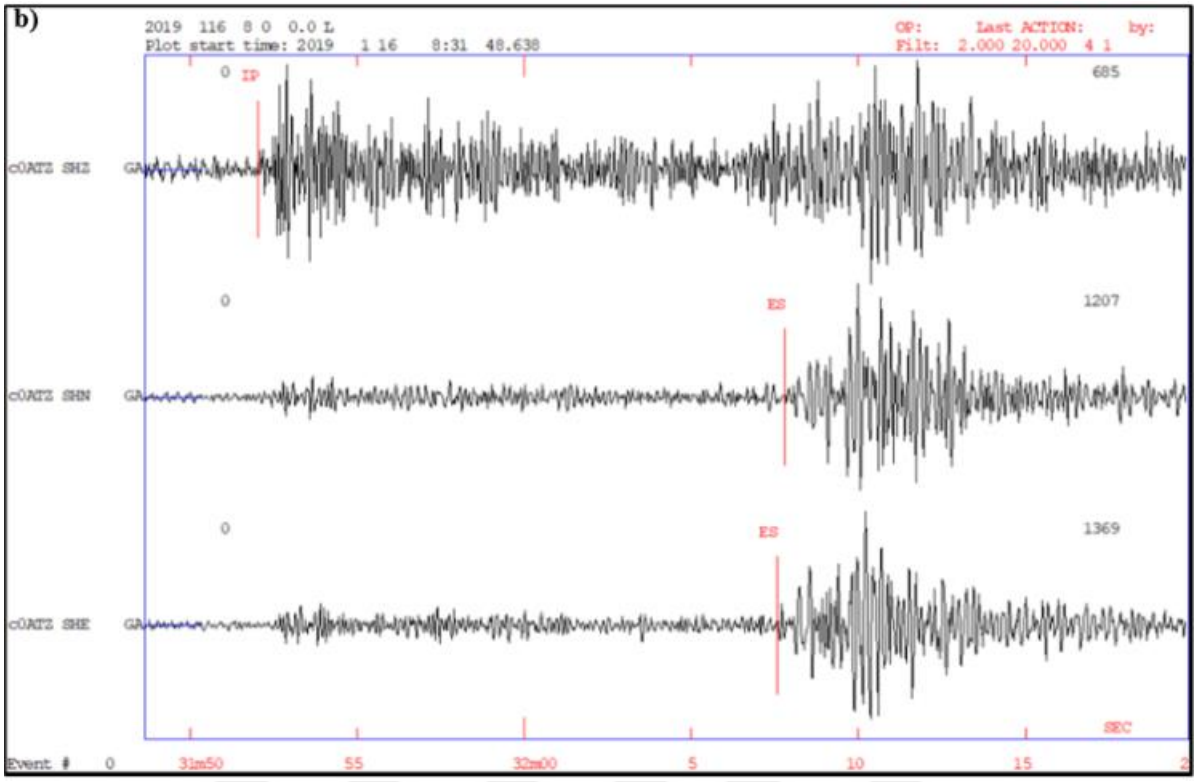
Şekil 4.13'te örnek bir istasyon kaydında manuel olarak keşfedilen ancak Tablo 4.2'de verilen STA 0.3 s LTA 30 s pencere süreleri ile tespit edilemeyen bir deprem kaydı gösterilmektedir. Şekil 4.14'te depremin P ve S dalga varışları gösterilmiştir. P ve S dalga varışları arasındaki zaman farkının t_s- t_p= 15 sn olduğu görülmektedir. Depremin istasyona olan uzaklığı ise D=(t_s- t_p)*8=120 km'dir. Bilindiği üzere STA süresi ne kadar kısa olursa, tetikleyicinin kısa süreli yerel depremlere duyarlılığı, uzun süreli ve daha düşük frekanslı olan uzak depremlere kıyasla o kadar yüksek olacaktır. Ayrıca kısa bir LTA süresi ortaya çıkan sismik dalgaların yavaşça artan genliğinin az ya da çok ayarlanmasına izin vermektedir. Dolayısıyla STA/LTA oranı, artan STA'ya (oran artışının payı ve paydası) rağmen düşük kalmaktadır. Böyle depremlere karşı tetiklenme hassasiyeti etkili bir şekilde azaltmaktadır. Uzun bir LTA pencere süresi kullanıldığında, ortaya karşı çıkan depremlere karşı tetiklenme hassasiyeti artmaktadır. Çünkü LTA değeri ortaya çıkan sismik sinyalden çok hızlı etkilenmemektedir. Şekil 4.13'te verilen deprem istasyondan uzakta meydana gelen bir depremdir. Bu nedenle seçilen STA süresi 0.3 sn'den 0.5 sn'ye artırılarak uzak depremlere karşı hassas hale getirilmiştir. LTA süresi ise 30 sn'den 60 sn'ye artırılarak STA/LTA oranının, tetik eşik seviyesi (tetiklenme oranını) aşarak tetiklenmenin gerçekleşmesi sağlanmıştır. Tablo

4.9'da depremin 7 istasyonda tetiklendiği görülmektedir. Şekil 4.15'te tetiklenen istasyonların STA/LTA grafikleri verilmiştir.



Şekil 4.13: 2019.01.16 tarihinde saat 08:31:52'de istasyonlara ulaşan depremin görüntüsü.

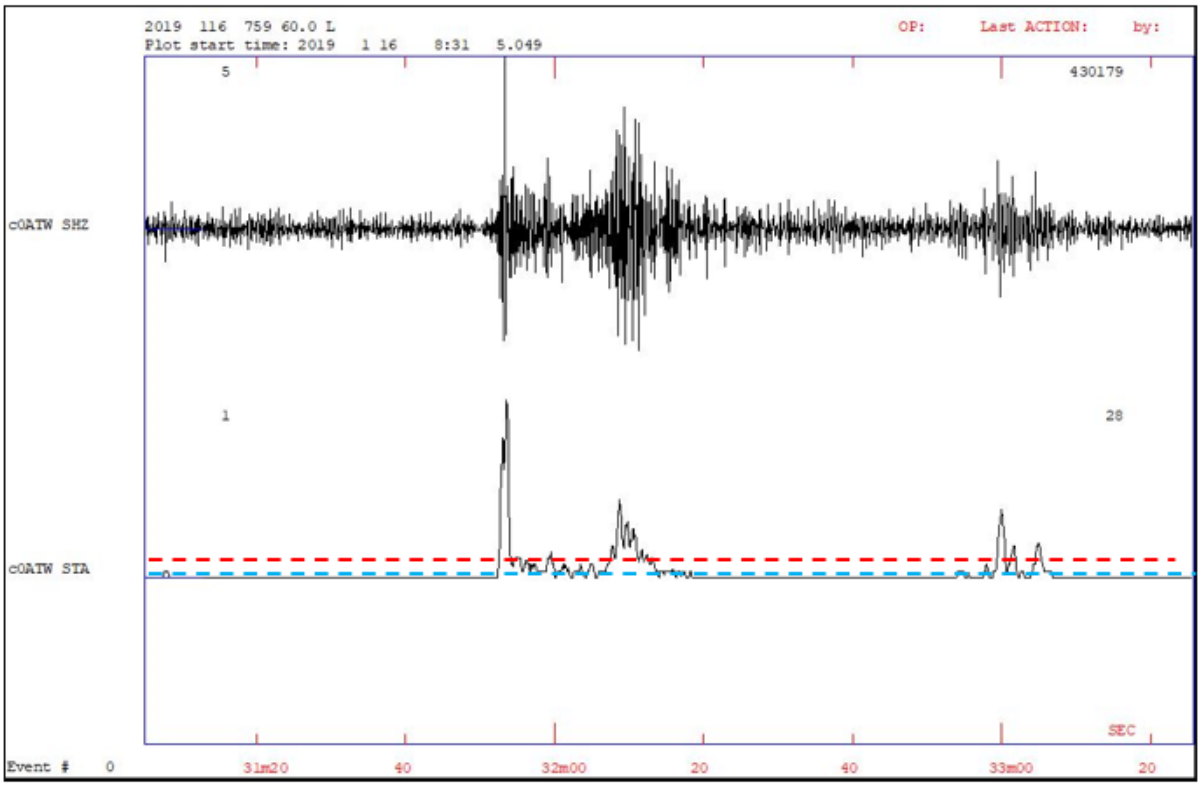


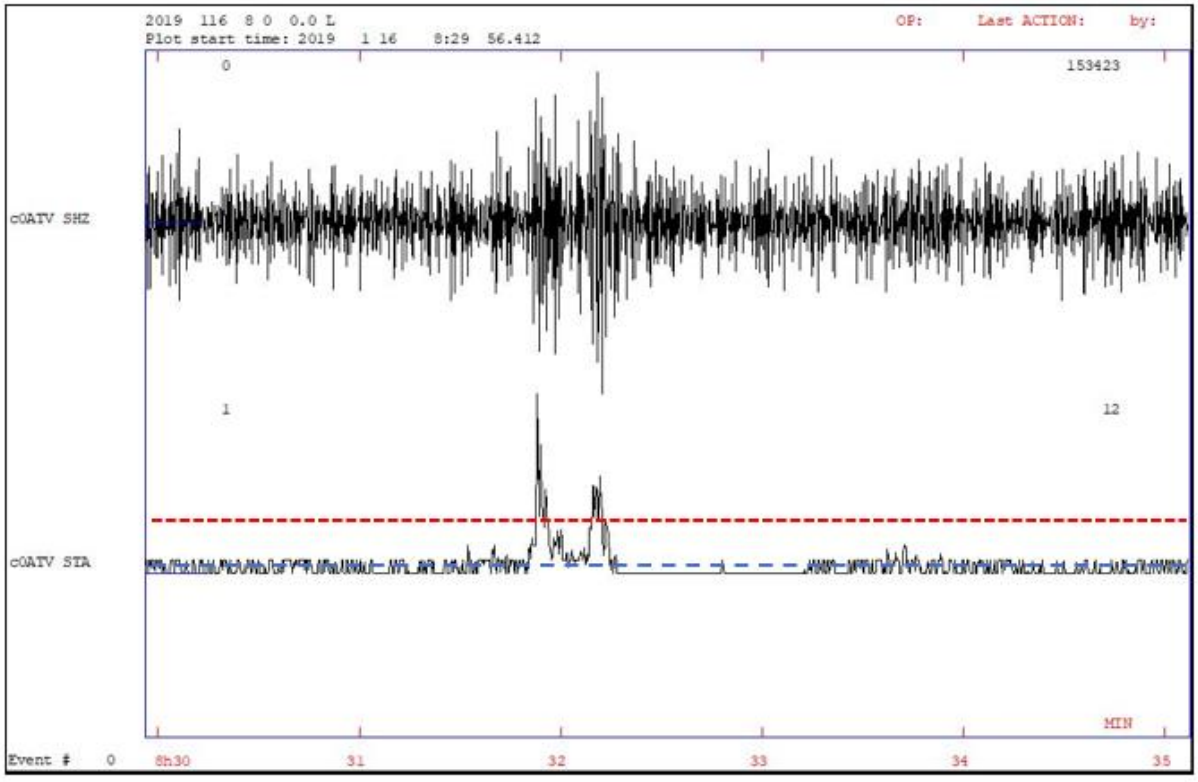


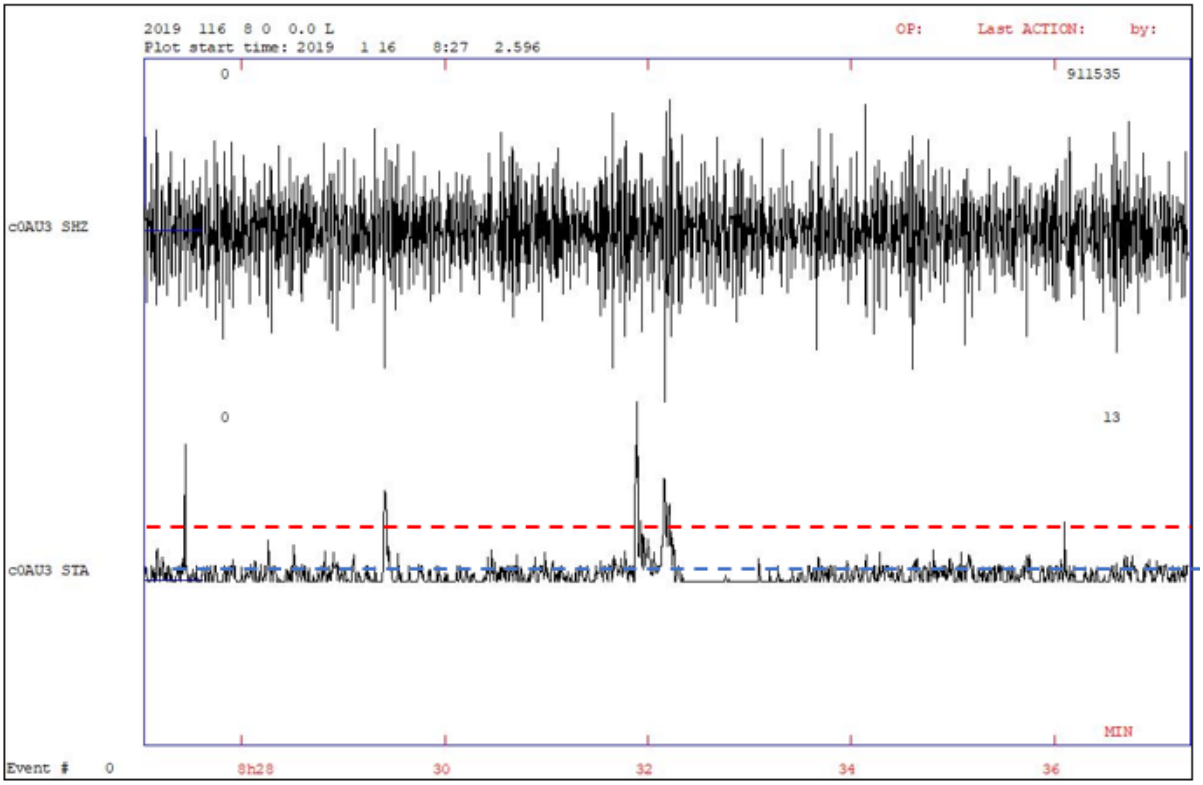
Şekil 4.14: a)2019.01.16 tarihinde saat 08:31:55'te istasyonlar tarafından kaydedilen depremin istasyonlardaki düşey bileşen kayıtları b) c0ATZ istasyonundaki üç bileşen deprem kaydı ve P, S fazlarının işaretlenmesi.

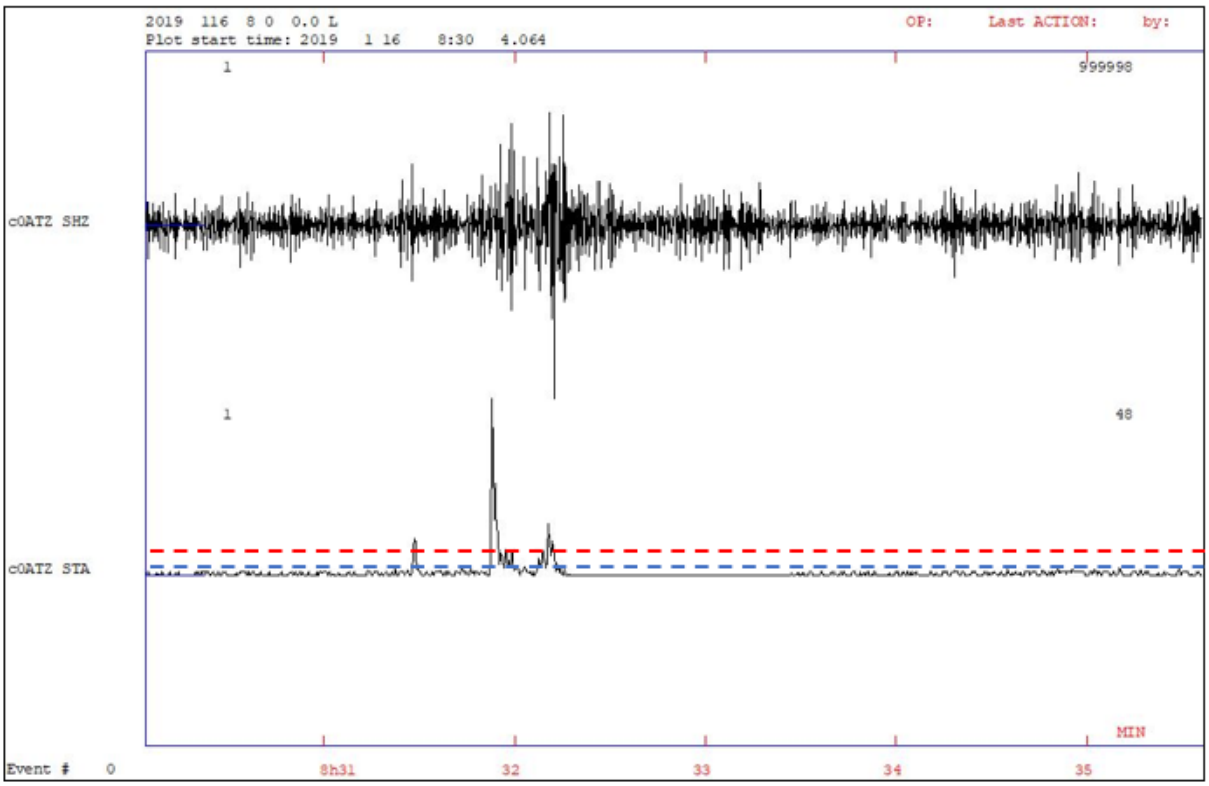
Tablo 4.9: STA 0.5 s ve LTA 60 s seçilmesiyle **condet.out** dosyasında verilen tetiklenen istasyonlar.

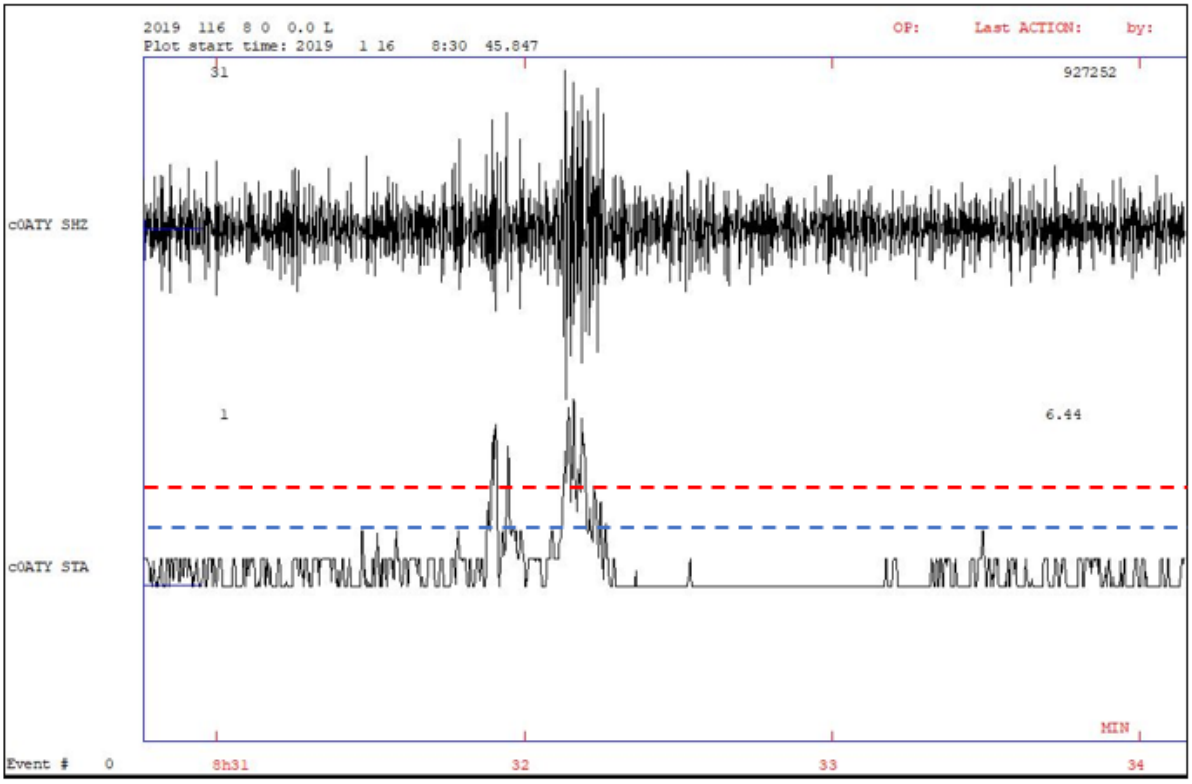
İstasyon	Deprem	Saat	Tetiklenme Uzunluğu	STA/LTA Oranı
c0ATW	2019/01/16	08:31:52	1.8	29.2
c0ATV	2019/01/16	08:31:52	4.2	13.2
c0AU3	2019/01/16	08:31:52	2.0	13.8
c0ATZ	2019/01/16	08:31:52	7.2	49.9
c0ATY	2019/01/16	08:31:53	1.4	6.8
c0AU1	2019/01/16	08:31:53	2.1	6.2
c0AU0	2019/01/16	08:31:53	1.5	5.5

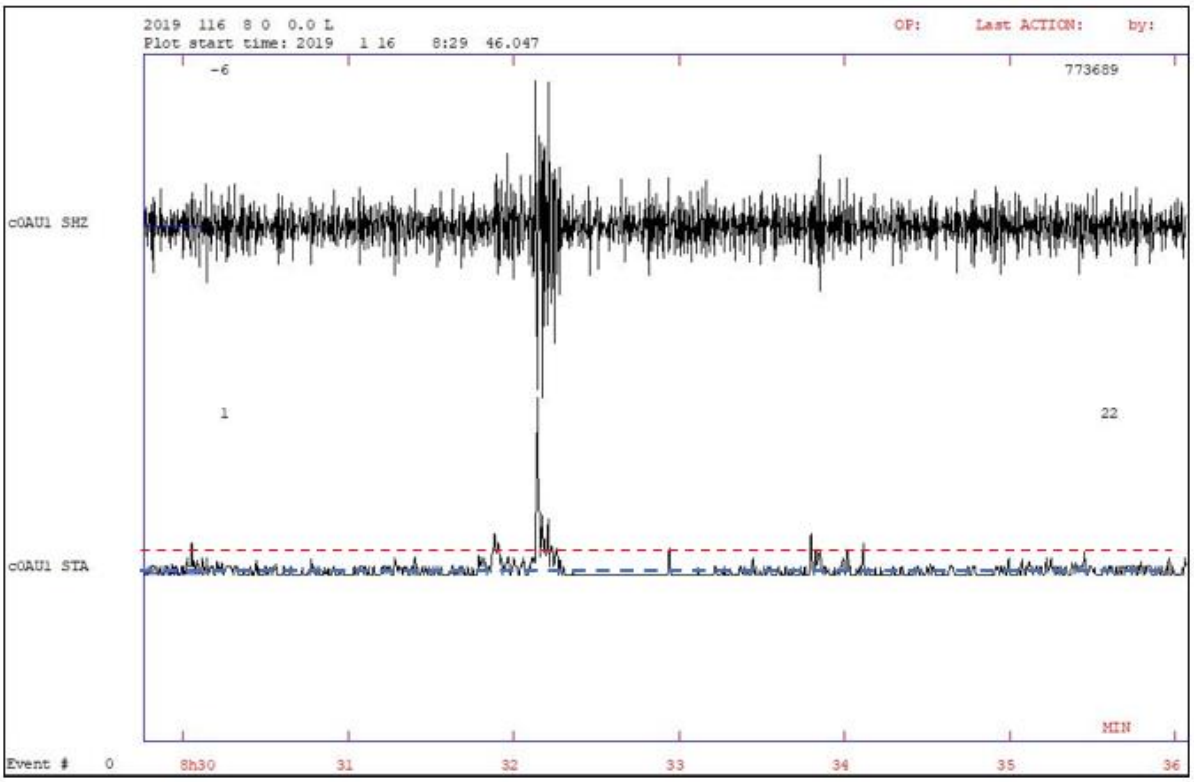

2019 116 759 60.0 L
Plot start time: 2019 1 16 8:31 5.049
OP: Last ACTION: by:
5
430179
c0ATW SHZ
1
28
c0ATW STA
SEC
Event # 0
31m20
40
32m00
20
40
33m00
20

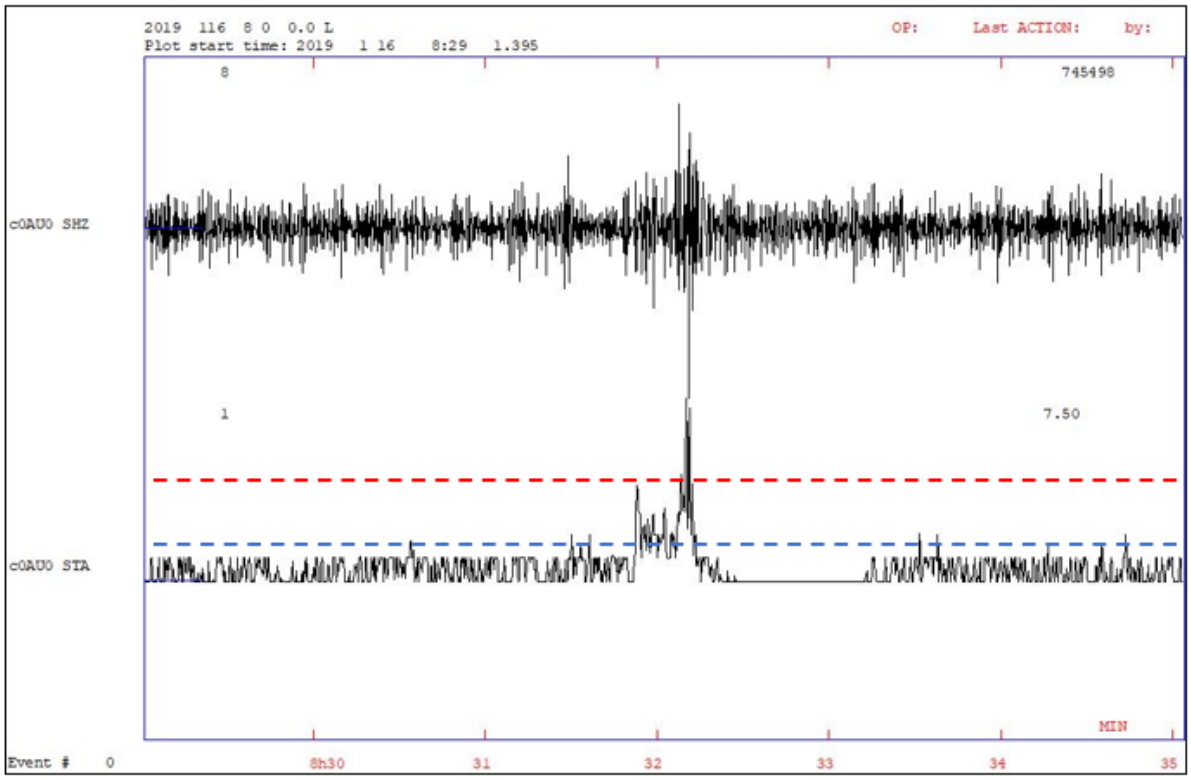

2019 116 8 0 0.0 L
Plot start time: 2019 1 16 8:29 56.412
OP: Last ACTION: by:
0
153423
c0ATV SHZ
1
12
c0ATV STA
MIN
Event # 0
8h30
31
32
33
34
35


2019 116 8 0 0.0 L
Plot start time: 2019 1 16 8:27 2.596
OP: Last ACTION: by:
0
911535
c0AU3 SHZ
0
13
c0AU3 STA
MIN
Event # 0
8h28
30
32
34
36


2019 116 8 0 0.0 L
Plot start time: 2019 1 16 8:30 4.064
OP: Last ACTION: by:
1
999998
c0ATZ SHZ
1
48
c0ATZ STA
MIN
Event # 0
8h31
32
33
34
35


2019 116 8 0 0.0 L
Plot start time: 2019 1 16 8:30 45.847
OP: Last ACTION: by:
31
927252
c0ATY SHZ
1
6.44
c0ATY STA
MIN
Event # 0
8h31
32
33
34

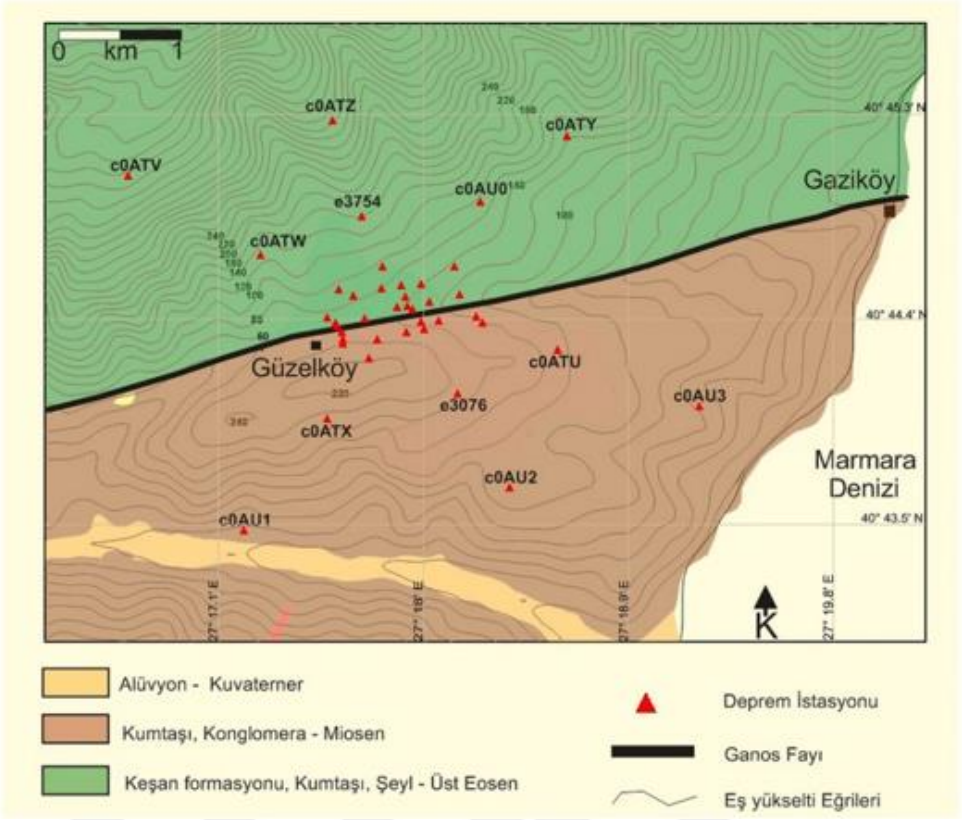

2019 116 8 0 0.0 L
Plot start time: 2019 1 16 8:29 46.047
OP: Last ACTION: by:
-6
773689
c0AU1 SHZ
1
22
c0AU1 STA
MIN
Event # 0
8h30
31
32
33
34
35
36



Şekil 4.15: Tablo 4.9'da verilen tetiklenen istasyonların STA/LTA grafikleri. Kesikli kırmızı çizgi STA/LTA oranının 5'i aştığı genlikleri, mavi kesikli çizgi ise oran değerlerinin yeniden olağan seviyeye düştüğü sınırı göstermektedir.

4.2 FAST ANALİZLERİ

Bu tez kapsamında FAST algoritması kullanılarak MONGAN ağından seçilen 7 istasyon (Şekil 4.16) kullanılarak 2019.01.02-2019.01.31 tarihleri arasındaki bir aylık veri içinde benzer dalga formlarına sahip depremleri tespit etmek ve FAST'in algılama yeteneğinin STA/LTA yöntemi bulgularını ne oranda geliştirebileceği araştırılmıştır. FAST analizi için seçilen istasyonlar, STA/LTA yönteminde kullanılan istasyonlarla birebir örtüşmez. Burada asıl etken daha uzun kayıt sürekliliğine sahip istasyonların analize dahil edilmesidir. Ayrıca, programın çalıştırılmasında sınırlı işlemci gücüne sahip kişisel bir bilgisayarın kullanılması nedeniyle, daha az sayıda istasyon kullanılarak analiz yapılabilmiştir. Seçilen 7 istasyona ait koordinat bilgileri Tablo 4.10'da verilmiştir. FAST'deki istasyon seçiminde aynı şekilde STA/LTA yöntemindeki gibi ağ içinde uzak ve kayıt sürekliliği olan istasyonlar dikkate alınmıştır. FAST algoritması çalıştırılmadan önce sürekli veriye, araştırması yapılan yakın depremler göz önünde bulundurularak 2-20 Hz bant geçişli filtre uygulanmıştır. Daha sonrasında filtrelenmiş verileri saniye de 200 Hz örneklemeden saniye de 20 Hz örnekleme oranına azaltılarak FAST algoritmasının daha hızlı ve verimli çalışması amaçlanmıştır.



Şekil 4.16: MONGAN-1 ağı istasyon dağılımı (üçgenler) ve yüzey jeolojisi. Sadece ağın dış istasyonlarının kodları gösterilmiştir (Yalçınkaya ve diğ., 2020).

Tablo 4.10: FAST analizi için seçilen 7 istasyona ait lokasyon bilgisi. Analizlerde e3754 kodlu istasyonun üç bileşen kaydı kullanılırken, diğer istasyonların sadece düşey bileşenleri kullanılmıştır.

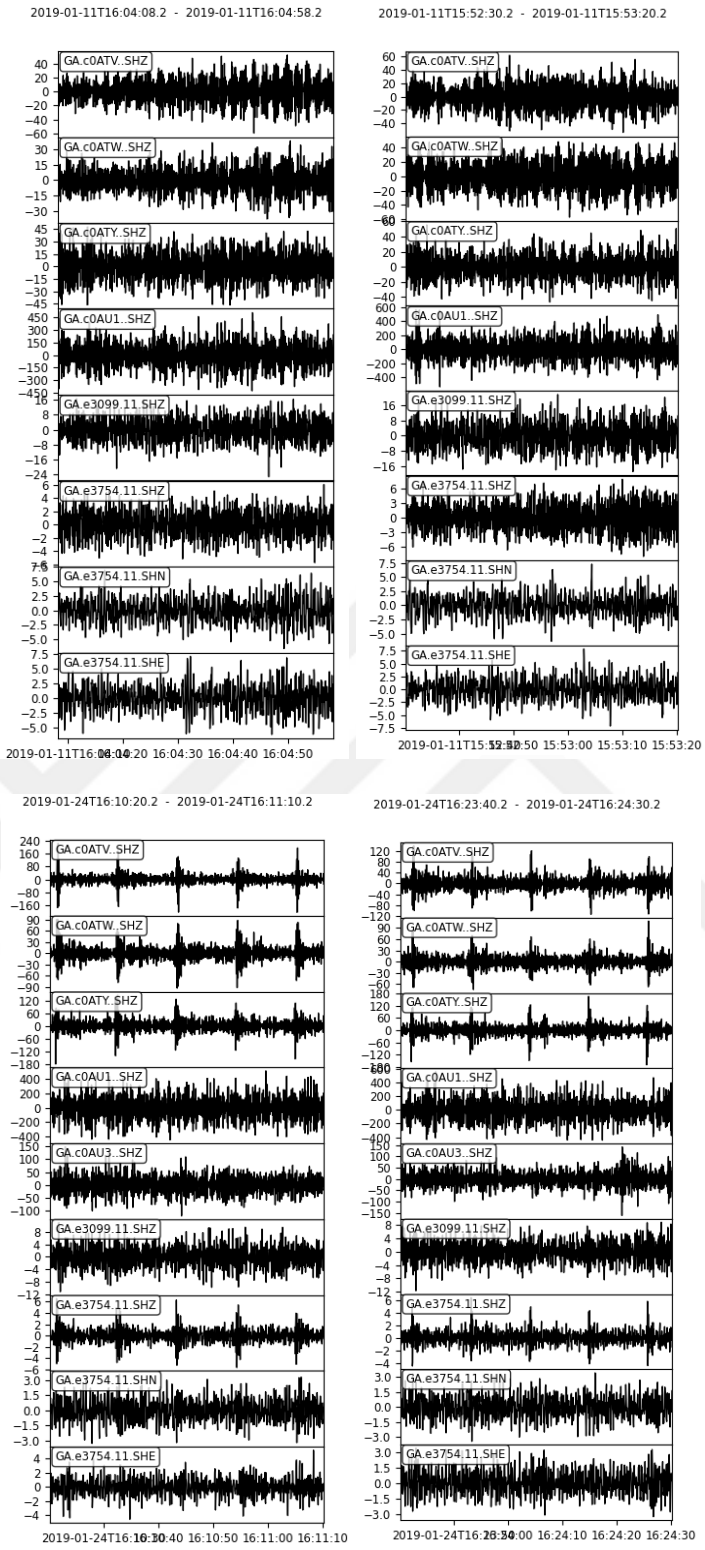
İSTASYON.KANAL	ENLEM	BOYLAM
c0ATV SHZ	40.75051	27.27847
c0ATY SHZ	40.75340	27.31056
c0ATW SHZ	40.75051	27.27847
c0ATZ SHZ	40.75458	27.29341
c0AU1 SHZ	40.72463	27.28697
c0AU3 SHZ	40.73362	27.32027
e3754 SHZ	40.74761	27.29553
e3754 SHE	40.74761	27.29553
e3754 SHN	40.74761	27.29553

FAST sürekli veri setindeki benzer dalga formu çiftlerini belirleyen veri madenciliği tabanlı algoritmalardan biridir (Yoon ve diğ., 2015). Benzer kaynaklara sahip depremlerin

benzer dalga formları üretme eğiliminde olduğu gözlemine dayanan algılama için temel olarak benzerliği hedef alan bir dedektördür. Bu nedenle FAST tarafından işlenen sürekli verilerdeki diğer sinyallere benzemeyen farklı bir deprem sinyali bulmasını bekleyemeyiz. Örneğin, veriler 100 olay sinyali içeriyorsa ancak bunlardan yalnızca ikisi benzer dalga formlarına sahipse, FAST yalnızca iki algılamayı verecektir. Daha uzun süreli sürekli verilerin benzer deprem sinyalleri içerme olasılığı daha yüksektir. Bu nedenle FAST daha fazla sismik olayı ayıklayacaktır. Eğer veri tekrarlanmayan, farklı deprem sinyalleri içeriyor ise yeterli enerjiye sahip keskin (impulsive) bir varışa sahip olması koşuluyla bunu tespit etmek için STA/LTA yönteminin tercih edilmesi daha mantıklıdır.

Bu tez çalışmasında FAST algoritmasını çalıştırmak amacıyla sanal bilgisayar üzerinde kurulu 9 GB RAM'a sahip bir Linux işletim sistemi kurulmuştur. Ancak FAST için Linux işletim sisteminde en az 64 GB RAM gerekmektedir (Yoon ve diğ.,2015). Bu durum karşısında hedef seçilen bir aylık sürekli veri, sadece 2 günlük parçalar şeklinde çalıştırılabilmiştir. Bu durumda 2 günlük veriler halinde çalıştırıldığında elde edilen benzer deprem sayısının, bir aylık veri ile çalışıldığında elde edilecek benzer deprem sayısından çok daha az olacağı açıktır. Çünkü farklı 2 günler içinde benzer kaynaktan gelen depremler bir aylık veri ile çalışıldığında FAST tarafından algılanabilecek iken, 2 günlük veriler halinde çalışılması farklı 2 günlerdeki benzer depremlerin kaçırılmasına neden olacaktır.

FAST yüksek benzerliğe sahip herhangi bir dalga formu çiftini aday depremler olarak kabul ederek, daha önceden bilinmeyen olayları belirleyebilir. Ancak bu, FAST'ı yanlış algılamalara karşı da açık hale getirir. Tüm benzer dalga formu çiftleri depremlere atfedilemez. Benzer veya tekrarlayan dalga formları, yerel gürültü kaynaklı da olabilir. Şekil 4.17'de 2019.01.11 ve 2019.01.24 tarihlerinde tekrarlayan ve benzer dalga formlarına sahip, FAST tarafından olay olarak sınıflanan örnek dalga formları verilmektedir. Her iki tespitte deprem olmayıp, tekrarlayan gürültülerdir. 2019.01.11 tarihinde 16:04:08.2 ve 15:52:30.2 saatlerinde istasyonlar tarafından kaydedilen dalga formları, 2019.01.24 tarihinde ise 16:10:20.2 ve 16:23:40.2 saatlerinde istasyonlar tarafından kaydedilen tekrarlayan benzer dalga formlar oldukları görülmektedir. Görüldüğü üzere aynı sismik istasyonlarda neredeyse aynı dalga formları olarak görülmektedirler.



Şekil 4.17: 2019.01.11 ve 2019.01.24 tarihlerinde FAST tarafından aralarındaki yüksek benzerlik nedeniyle olay olarak sınıflanan ancak deprem olmayan olay çiftleri (tekrarlayan gürültüler).

FAST algoritması Tablo 4.11'de verilen parametreler ile ilk olarak dalga formunun ayırt edici özelliklerini ayıklayarak, dalga formu parmak izi olarak adlandırılan parmak izlerini oluşturmaktadır. Daha sonrasında tüm parmak izlerini LSH (Locality-Sensitive Hashing) fonksiyonları kullanılarak bir veri tabanı oluşturmaktadır. LSH, bir H fonksiyon sınıfından olan MinHash fonksiyonunu kullanarak verilen bir parmak izini Min-Hash Signature (MHS) olarak adlandırılan bir ***p*** işaretsiz tamsayı dizisine dönüştürmektedir (Leskovec ve diğ., 2014). Minhash fonksiyonu ile her parmak izinin boyutsallığını 4096 elemanlı bir bit vektöründen daha kısa bir tamsayı dizisine indirgemektedir (bkz. Bölüm 3.2.3.)

Oluşturulan veri tabanı ***b*** karma tablolarından oluşan bir koleksiyondur. Bir ***b*** karma tablo birçok ***v*** karma kova ve parmak izlerinin farklı karma kovalar arasında nasıl dağılacağını belirleyen ***r*** karma fonksiyonlar içermektedir. Karma tablolar yüksek olasılıkla benzer olan ve aynı karma kova içinde birlikte gruplandırılan benzer parmak izlerinden oluşan bir veri tabanıdır. Karma tabloda depolanan her dalga formu parmak izi bir dizin/anahtar değeri ile ilişkilidir. Bu dizin/anahtar değeri ise yukarıda bahsedilen MinHash fonksiyonu kullanılarak atanmaktadır. Spesifik olarak, her bir karma tabloya sabit bir ***r*** Minhash fonksiyon dizisi atanmaktadır. ***r*** MinHash fonksiyonu ile her parmak izi için bir ***r***- *tamsayı "MinHash signature" (MHS)* üretilmektedir. Daha sonrasında *MHS*'deki ***r*** tamsayı değerleri, tek bir karma anahtar (hash key) oluşturmak üzere birleştirilmektedir (Bergen, 2018). Her karma anahtar (hash key) bir karma kovanın yerini alan 64 bitlik bir tamsayı dizinidir ve birden çok değer (parmak izi için referanslar) içermektedir. Verilen bir karma tablo için eğer ***A*** ve ***B*** aynı karma anahtarı paylaşıyor ise aynı karma kova içine yerleştirileceklerdir (bkz. Şekil 3.12). Aksi takdirde; farklı karma kova içine yerleştirileceklerdir (Leskovec ve diğ., 2014; Baluja ve Covell, 2008).

FAST veri tabanındaki her parmak izini bir "**arama sorgusu**" olarak kullanmaktadır. Benzerlik arama sırasında, belirli bir **'arama sorgusu parmak izi'** için benzer tüm parmak izlerini veri tabanından çağırmaktadır (bkz. Şekil 3.13). Yoon ve diğ., (2015) tarafından FAST benzerlik; aynı karma kovadaki parmak izini içeren karma tablolarının kesri olarak tanımlamaktadır. Örneğin ***b***=100 karma tablonun en az ***v***=4'ünde görünen çiftin FAST benzerlik eşiği 4/100=0.04'tür ve bunlar **"aday deprem dalga formları"** olarak adlandırılmaktadır. FAST, LSH uygulamasında parmak izlerini karşılaştırmak için bir benzerlik metriği olan Jaccard benzerliğini kullanmaktadır. İki parmak izinin, tablo başına ***r*** karma fonksiyonuna sahip ***b*** karma tabloların en az ***v***'sinde aynı karma kovaya yerleştirilme olasılığı Jaccard benzerliklerinin bir fonksiyonu olarak verilmektedir (bkz.Denklem 3.9). Başarılı bir

benzerlik arama için gereken yüksek Jaccard benzerliği ***r, b*** ve ***v*** parametrelerine bağlıdır. Seçilen büyük bir ***r*** değeri için çok sayıda karma kova elde edilirken, bu kovalar içinde ortaya çıkan düşük parmak izi yoğunluğu kaçırılan algılamalara neden olabilmektedir. Fakat ***r*** değerinin çok küçük seçilmesi halinde çok az karma kova elde edilmesine ve her kovada çok fazla parmak izi olmasına neden olacaktır. Bu durum da hem benzer parmak izi arama süresi hem de yanlış algılama olasılığı artacaktır. Seçilecek yüksek ***b*** değeriyle çok fazla karma tabloya sahip olmak aynı kovada iki parmak izi bulma olasılığını artırmaktadır. Ancak daha fazla bellek gereksinimine, çalışma süresine ve yanlış algılamalara neden olabilmektedir (Leskovec ve diğ., 2014). Seçilecek yüksek ***v*** değerleri başarılı benzerlik araması için iki parmak izi arasında yüksek Jaccard benzerliğini gerektirecektir. FAST benzerlik arama sonucunda seyrek bir benzerlik matrisi elde edilmektedir. Benzerlik arama adımının en önemli özelliği sadece nispeten yüksek benzerliğe sahip parmak izi çiftlerini geri vermesidir. Düşük benzerliğe sahip tüm parmak izi çiftlerine sıfır değeri atanmaktadır. Böylelikle benzerlik matrisi seyrek hale gelmektedir. Matrisin her satırı ve sütunu belirli bir dalga formu parmak izine karşılık gelmektedir ve matris değerleri parmak izleri arasındaki benzerliğin bir ölçüsüdür. Çıktı matristeki sıfır olmayan değerlere karşılık gelen üçlü bir liste şeklinde döndürülmektedir. Her üçlü çiftteki her parmak izinin tamsayı indeksini ve bunlara karşılık gelen benzerlik değerini içerir: (i, j, m_{ij}). Yukarıda bahsedildiği üzere FAST dedektörünün hassasiyeti Tablo 4.11'de verilen LSH fonksiyonları olan ***r, v*** ve ***b*** parametrelerine bağlıdır. Bu tez çalışmasında LSH parametre kılavuzunda tavsiye edilen bir değer olarak ***b*** karma tablo sayısı sabit olarak 100 değeri alınmıştır. Ayrıca verinin 2 günlük veriler halinde çalıştırılması nedeniyle seçilecek çok fazla karma tablo sayısı yanlış algılama sayısının artmasına neden olacaktır. LSH parametre kılavuzunda yer alan kısa süreli veri setleri (gün- haftalık) için tavsiye edilen ***r*** tablo başına karma fonksiyon sayısı değeri olarak ***r***=4 değeri seçilmiştir. Daha sonrasında ***r***=5 değerine kadar artırılmıştır.

FAST benzerlik arama sonucu elde edilen çıktıya üç adımlı ağ algılama ardışık düzeni (bkz. Şekil 3.16) uygulanmıştır: olay çifti çıkarma (event-pair extraction), ikili sözde ilişkilendirme (pairwise pseudo-association) ve olay ayrımı (event-resolution). Tablo 4.12'de üç adımlı ağ algılama ve kullanılan parametre değerleri verilmiştir.

Tablo 4.11: Tablo 4.10'da verilen istasyonlardaki sürekli sismik verideki her bileşende depremleri tespit etmek için kullanılan FAST giriş parametreleri.

PARAMETRELER	DEĞERLER
Spektrogram üretmek için zaman penceresi uzunluğu	6 s
Spektrogram üretmek için zaman penceresi gecikmesi	0.2 s
Spektral görüntü pencere uzunluğu	12.4 s
Spektral görüntü pencere gecikmesi	1 s
Spektral görüntü genişliği	32 örnekleme
En yüksek genlik k standardize Haar katsayılarının sayısı	200
LSH: tablo başına karma fonksiyon sayısı r	4
LSH: karma tablo sayısı b	100
Başlangıç çift eşik seviyesi: aynı kova içindeki çiftin tablo sayısı	2 (2/100=0.02)
Benzerlik arama: tekrara yakın hariç tutma parametresi	5 s

Tablo 4.12: Bergen ve Beroza'dan (2018) ikili ilişkilendirme ve ağ algılama için giriş parametreleri.

OLAY ÇİFT ÇIKARMA PARAMETRELERİ	**DEĞERLER**
Zaman boşluğu (köşegen boyunca),g_L (dgapL)	1 sn
Zaman boşluğu (bitişik köşegen),g_w (dgapW)	1 sn
Bitişik köşegen birleştirme iterasyonu, p (num_pass)	2
OLAY ÇİFT AYIKLAMA PARAMETRELERİ	**DEĞERLER**
İstasyon-çift eşik seviyesi, τ0	6 (ivals_thresh)
Minimum parmak izi çiftleri, —C—min	4 (min_dets)
Minimum toplam benzerlik	24
Maksimum sınırlayıcı kutu genişliği	8 s (max_width)
SÖZDE İLİŞKİLENDİRME PARAMETRELERİ	**DEĞERLER**
Algılama için minimum istasyon sayısı (nsta_thresh)	4 (7 istasyondan)
Varış süresi kısıtlaması, maksimum zaman aralığı,g_N (input_offset)	3 s

Bu üç adımlı ağ algılama ardışık düzenin sonucunda elde edilen ham FAST çıktı dosyalarında kullanılan parametrelere bağlı olarak hala yinelenen olaylar (duplicate events) olabilmektedir. Tek bir istasyonda gözlenen olaylar nedeniyle bu yinelemeler ağdaki farklı olay çiftlerine karşı diğer algılamalarla farklı şekilde gruplandırılabilir. Bu olayları kaldırmak ve olay algılamalarının son bir listesini oluşturmak amacıyla 2 adımdan oluşan bir işlem yapılmaktadır. Aşağıda bu işlemler hakkında bilgiler verilmiştir.

Birinci adımda "remove_duplicates_after_network_detections.py" dosyası çalıştırılarak olaylara ait başlangıç parmak izlerinden tekrarlayan başlangıç parmak izleri kaldırılmıştır. Bu adımın sonuçları "uniquestart_sorted_no_duplicates.txt**"** dosyasına yazılmıştır. Örneğin; Tablo 4.13'te FAST'in üç adımlı ağ algılama adımları sonucunda 02.01.2019-03.01.2019 tarihlerinde elde edilen ham olay sayısı 919'dur. Bu ham FAST çıktısına uygulanan 1. adım ile 919 olay sayısı 216'ya inmiştir. Böylelikle 703 tekrarlayan olay listeden kaldırılmıştır.

İkinci adımda örtüşen zaman olayları (bir olayın başlangıç zamanı başka bir olayın bitiş zamanından önceyse) silmek amacıyla "Python delete_overlap_network_detections.py" dosyası çalıştırılmıştır. Bu adımın sonuçları "7sta_2stathresh_FinalUniqueNetworkDetection-Times.txt" dosyasına yazılmıştır. Örneğin Tablo 4.13'te 02.01.2019-03.01.2019 tarihlerinde uygulanan ikinci adım ile 216 olay sayısından 100 olay sayısına inmiştir.

Yukarıda anlatılan 2 adımın uygulanması sonucunda tekrarlayan ve örtüşen zamanlı olayların algılama listesinden kaldırılmasının ardından listede var olabilecek yanlış algılamaların (deprem olmayan, gürültü) listeden çıkarılması gerekmektedir. Bu nedenle olayların manuel (göz ile) incelemesinin yapılması amacıyla FAST algoritmasında kullanılan "PARTIALplot_GANO_detected_waveforms.py" dosyası çalıştırılarak listede var olan olayların '.png dosyaları' çizdirilmiştir. Örneğin Tablo 4.13'te 02.01.2019-03.01.2019 tarihlerinde yukarıda uygulanan 2 adımın sonucunda elde edilen 100 olay sayısının göz ile incelenmesi sonucunda 91 olayın yanlış algılama olduğu tespit edilmiştir.

Tablo 4.13, Tablo 4.14, Tablo 4.15, Tablo 4.16, Tablo 4.17, Tablo 4.18'de farklı ***r*** ve ***v*** parametrelerine bağlı olarak yapılan FAST algılamaları sonucunda elde edilen ham olay sayıları ve daha sonrasında bu ham olaylar arasında tekrarlanan olayları kaldırmak amacıyla yukarıda bahsedilen 2 adımın uygulanması sonucu her bir adımda elde edilen olay sayıları verilmiştir. Son olarak 2. adım sonucunda elde edilen olay sayılarında yapılan göz ile inceleme de tespit edilen olay sayıları ve yanlış algılanan olay sayıları verilmiştir. Tablo 4.13'te 08-09 günler ve Tablo 4.18'de 16-17 günler için c0ATW istasyonundan aday çiftler elde etmek amacıyla olay çifti çıkarımının gerçekleşmemesinden kaynaklı olarak algoritma bu aşamada çalışamamıştır.

Tablo 4.13: *r*=4 *v*=2 parametreleri sonucunda elde edilen olay sayıları.

GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	919	216	100	9	91	91
04-05	362	33	18	4	14	77.7
06-07	1866	347	139	0	139	100
08-09	-	-	-	-	-	-
10-11	903	179	95	11	84	88.42
12-13	1061	211	90	10	80	88.8
14-15	326	106	55	6	49	89.09
16-17	1519	477	267	0	267	100
18-19	1477	350	180	19	161	89.4
20-21	4393	623	253	6	247	97.62
22-23	2825	390	193	4	189	97.92
24-25	1682	301	137	6	131	95.62
26-27	2450	491	242	7	235	97.10
28-29	1357	356	176	20	156	88.63
30-31	1934	437	199	12	187	93.96
Toplam Olay Sayısı				114	Ortalama Hata Yüzdesi	92.51

Tablo 4.14: *r*=4 *v*=3 parametreleri sonucunda elde edilen olay sayıları.

GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	409	89	42	7	35	83.33
04-05	359	33	18	0	18	100
06-07	645	159	69	0	69	100
08-09	316	99	50	2	48	96
10-11	560	139	66	10	56	84.84
12-13	466	176	76	6	70	92.10
14-15	89	47	30	5	25	83.33
16-17	679	147	76	0	76	100
18-19	1477	350	180	19	161	89.44
20-21	1797	404	168	6	162	96.42
22-23	1203	219	100	4	96	96
24-25	1205	219	103	0	103	100
26-27	1330	272	138	2	136	98.55
28-29	628	192	97	17	80	82.47
30-31	262	202	88	1	87	98.86
Toplam Olay Sayısı				79	Ortalama Hata Yüzdesi	93.42

Tablo 4.15: *r*=4 *v*=4 parametreleri sonucunda elde edilen olay sayıları.

GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	919	216	100	4	96	96
04-05	174	23	11	0	11	100
06-07	366	101	47	0	47	100
08-09	138	58	36	2	34	94.4
10-11	257	87	53	6	47	88.67
12-13	268	106	54	2	52	96.29
14-15	58	28	17	6	11	64.70
16-17	390	54	22	0	22	100
18-19	296	87	49	17	32	65.30
20-21	846	239	118	4	114	96.61
22-23	756	147	68	0	68	100
24-25	368	93	55	4	51	92.72
26-27	783	203	114	2	112	98.24
28-29	341	89	55	14	41	74.54
30-31	234	103	57	1	56	98.24
Toplam Olay Sayısı				62	Ortalama HataYüzdesi	91.04

Tablo 4.16: *r*=5 *v*=2 parametreleri sonucunda elde edilen olay sayıları.

GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	236	58	35	4	31	88.57
04-05	152	28	9	0	9	100
06-07	343	113	48	0	48	100
08-09	94	46	33	2	31	93.93
10-11	968	159	85	12	73	85.88
12-13	257	85	47	2	45	95.74
14-15	37	20	11	6	5	45.45
16-17	394	64	26	0	26	100
18-19	329	110	53	15	38	71.69
20-21	848	220	117	2	115	98.29
22-23	727	138	66	0	66	100
24-25	381	84	47	4	43	91.48
26-27	683	201	95	0	95	100
28-29	298	90	47	10	36	76.59
30-31	217	101	66	1	65	98.48
Toplam Olay Sayısı				58	Ortalama HataYüzdesi	89.74

Tablo 4.17: *r*=5 *v*=3 parametreleri sonucunda elde edilen olay sayıları.

GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	133	29	15	4	11	73.3
04-05	97	39	15	0	15	100
06-07	343	113	48	0	48	100
08-09	24	17	13	2	11	84.61
10-11	92	33	23	0	23	100
12-13	111	37	23	2	21	91.30
14-15	19	7	5	3	2	40
16-17	160	31	9	0	9	100
18-19	1477	350	180	19	161	89.44
20-21	316	106	54	2	52	96.29
22-23	269	60	24	0	24	100
24-25	187	54	25	5	20	80
26-27	355	98	57	3	54	94.73
28-29	171	47	28	8	20	71.42
30-31	40	22	18	0	18	100
Toplam Olay Sayısı				48	Ortalama HataYüzdesi	88.07

Tablo 4.18: *r*=5 *v*=4 parametreleri sonucunda elde edilen olay sayıları.

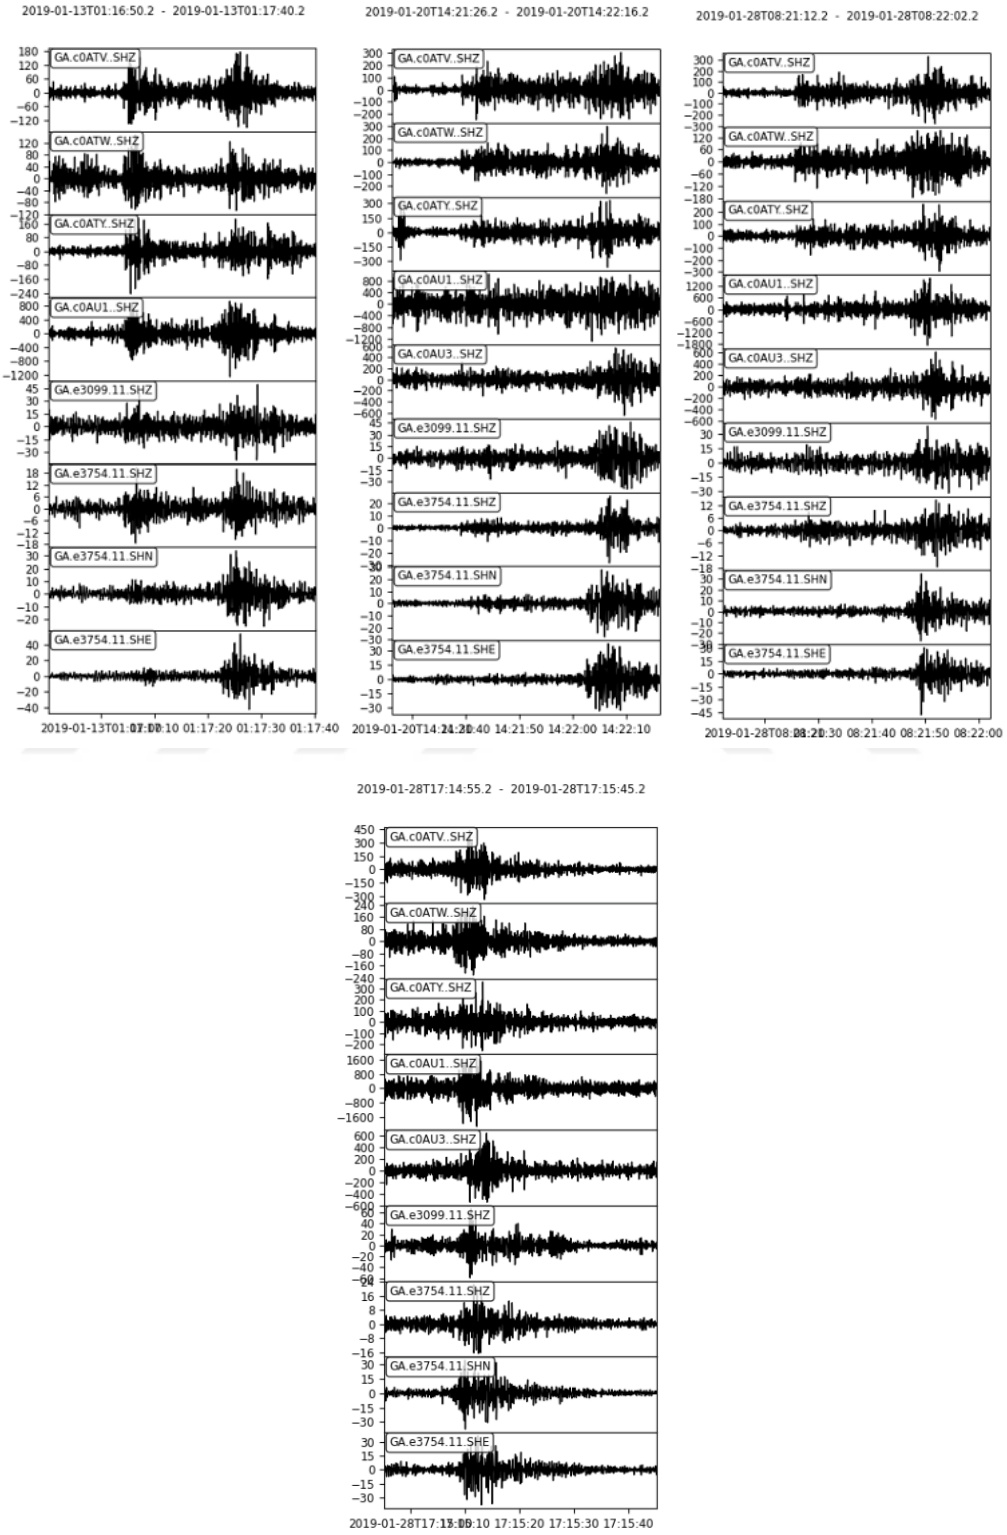
GÜNLER	HAM OLAY SAYISI	1.ADIM	2.ADIM	GÖZ	YANLIŞ OLAY SAYISI	HATA YÜZDESİ (%)
02-03	84	39	12	4	8	66.6
04-05	49	28	12	0	12	100
06-07	54	26	11	0	11	100
08-09	17	15	13	2	11	84.61
10-11	39	22	12	2	10	83.3
12-13	41	22	13	0	13	100
14-15	7	6	5	3	2	40
16-17	-	-	-	-	-	-
18-19	1477	350	180	20	160	88.8
20-21	166	62	29	1	28	96.5
22-23	172	38	17	0	17	100
24-25	69	39	26	4	22	84.61
26-27	216	55	36	2	34	94.44
28-29	132	32	21	9	11	52.38
30-31	9	5	4	0	4	100
Toplam Olay Sayısı				47	Ortalama Hata Yüzdesi	79.41

Tablo 4.13'te görüldüğü üzere ***r***=4 ***v***=2 kombinasyonu ile yapılan FAST algılama da %92.51 ortalama hata yüzdesiyle en yüksek olay sayısı (114 adet) elde edilmiştir. Diğer ***r*** ve ***v*** kombinasyonlarına kıyasla Tablo 4.18'de *r*=5 *v*=4 kombinasyonu ile yapılan FAST algılamada %79.41 en düşük ortalama hata yüzdesiyle en az olay sayısı (47 adet) elde edilmiştir. Hata oranlarının yüksek olmasında Tablo 4.11 ve Tablo 4.12'de seçilen parametre değerlerinden kaynaklı olarak gürültü içeren kayıtların benzer dalga formlarına ait depremler olarak algılanması nedeniyle yanlış algılama sayısının yüksek olmasına neden olmuştur. Tablolarda görüldüğü üzere ***r*** ve ***v*** parametre değerlerinin artmasıyla ham olay sayılarına uygulanan 2 adımlı son işlemler sonucunda 4. sütunda verildiği üzere olay sayılarının azaldığı görülmektedir. Ancak göz ile yapılan incelemelerde yanlış algılamaların ayıklanması sonucunda elde edilen doğru algılamaların (deprem) azaldığı görülmüştür. Tablo 4.13 ve Tablo 4.16'da ***v*** parametre değerleri *v*=2'dir. ***r*** değerleri ise Tablo 4.13 için *r*=4 ve Tablo 4.16 için *r*=5'tir. Tablo 4.13'te *r*=4 *v*=2 kombinasyonu ile toplam 114 olay algılanırken, Tablo 4.16'da *r*=5 *v*=2 kombinasyonu ile toplam 58 olay algılanmıştır. Görüldüğü üzere *r* değerlerinin artması algılanan olay sayısının azalmasına neden olmuştur. Çünkü; ***r*** değerlerinin artması parmak izlerinin konulduğu karma kova sayısının artmasına ve kovalardaki parmak izi yoğunluğunu düşürülmesine neden olmuştur. Bu durum kaçırılan algılamalara neden olmaktadır. Tablo 4.13 ve Tablo 4.14'te ***r*** parametre değerleri *r*=4'tür. ***v*** değerleri ise Tablo 4.13 için *v*=2 ve Tablo 4.14 için *v*=3'tür. Tablo 4.13'te *r*=4 *v*=2 kombinasyonu ile FAST tarafından toplam 114 olay algılanırken, Tablo 4.14'te *r*=4 *v*=3 kombinasyonu ile 79 olay algılanmıştır. Görüldüğü üzere ***v*** değerlerinin artması ile olay sayılarının azalmasına ve kaçırılan algılamalara neden olmuştur. Çünkü; ***v*** değerinin artması başarılı bir arama için iki parmak izi arasında daha yüksek bir Jaccard benzerliği gerektirmektedir. Görüldüğü üzere *r*=4 *v*=2 parametre kombinasyonu ile yapılan algılamada toplam algılama sayısı açısından daha yüksek bir sonuç verdiği görülmektedir.

Yapılan katalog taramasında *r*=4 *v*=2 parametresi ile algılanan 114 depremin 49'u katalog da yer alırken, 65'i katalogda bulunmamaktadır. ***r***=4 ve ***v***=2 parametreleri ile yapılan 2 günlük veriler şeklindeki algılamalarda elde edilen depremler dalga formu benzerliklerine göre gruplandırılmıştır (bkz. **EK 1**).

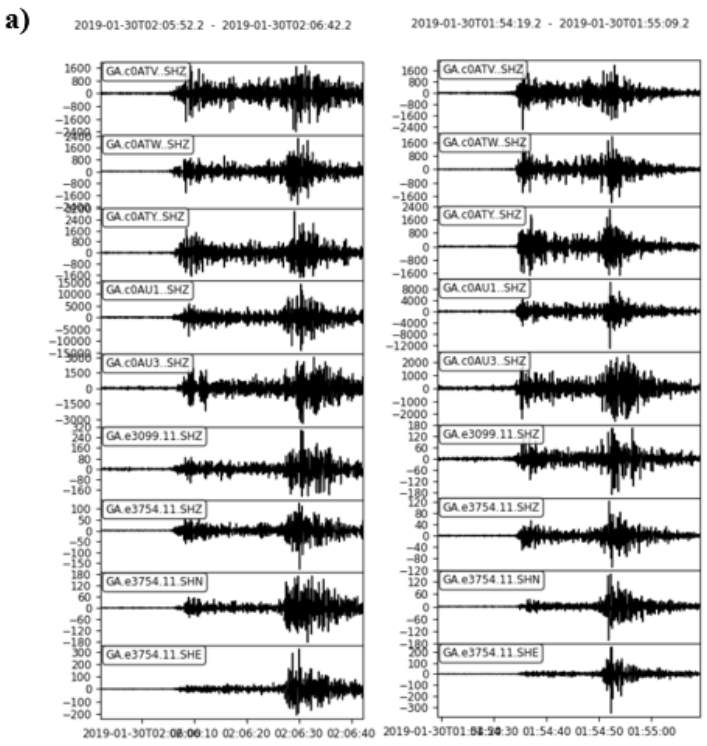
Şekil 4.18'de sadece *r*=4 ve *v*=2 parametre kombinasyonu ile FAST tarafından algılanan ancak STA/LTA tarafından tespit edilemeyen 4 depremin istasyonlardaki kayıtları verilmiştir. Depremler yapılan göz ile kontrolde tespit edilebilmiştir. 2019.01.28 tarihinde saat 17:14.55.2 kayıtlı deprem haricinde diğer 3 depremin katalog da yer aldığı belirlenmiştir (Tablo 4.19).

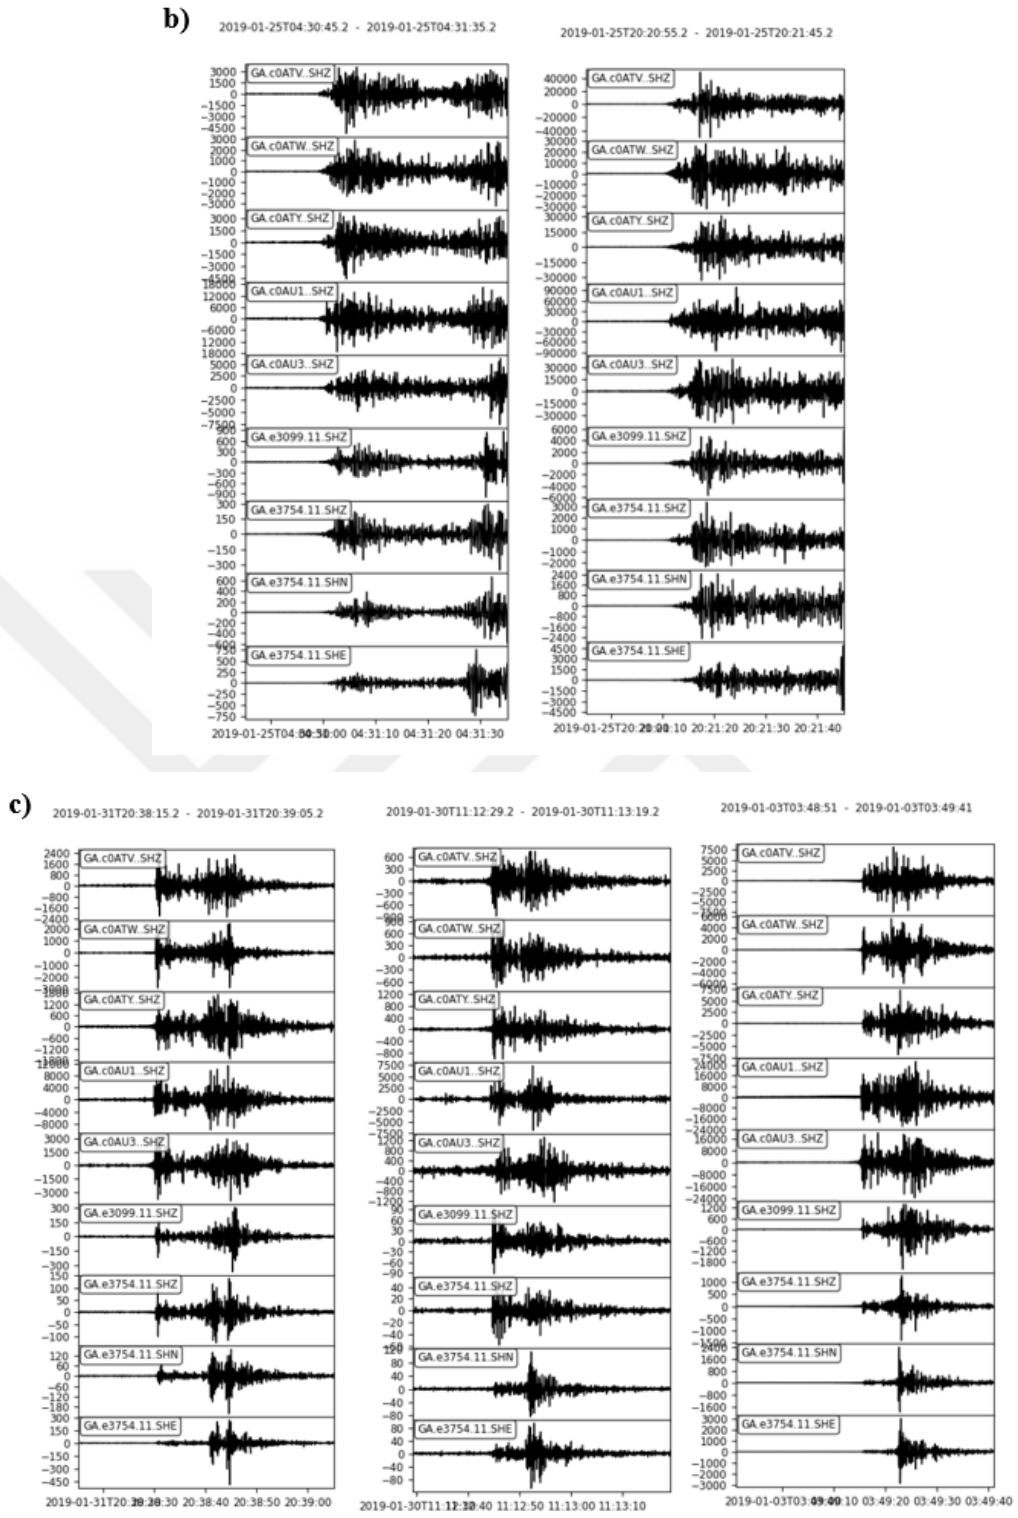
Şekil 4.18'de verilen depremlerin büyüklükleri sırasıyla 1.7, 1.9, 2.1 olduğu belirlenmiştir. FAST tarafından algılanan bu depremler tetik eşik seviyesini aşamadığından STA/LTA yöntemi tarafından tespit edilemediği belirlenmiştir.



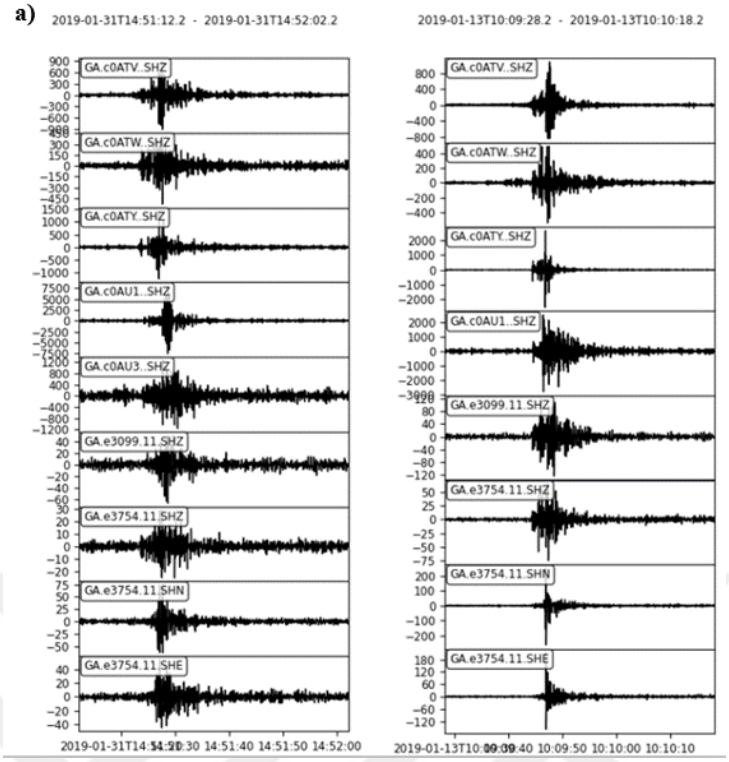
Şekil 4.18: *r*=4 *v*=2 kombinasyonu tarafından tespit edilebilen ancak STA/LTA ile tespit edilemeyen depremlere ait kayıtlar.

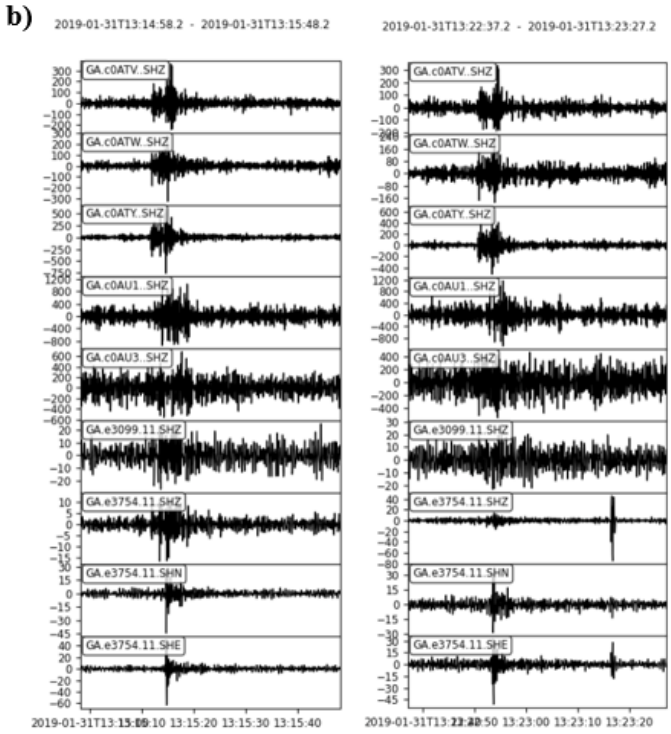
r=4 ve ***v***=2 kombinasyonu tarafından tespit edilen 114 deprem içerisindeki 31 depremin (bkz. **EK 2**) sadece bu kombinasyon tarafından algılandığı belirlenmiştir. Yapılan katalog taramasında tespit edilen 31 depremin 12'si istasyonlara yakın meydana gelen depremler (kısa ts-tp zamanları, Güzelköy açıkları-Tekirdağ) iken 19'u istasyonlardan uzakta (daha uzun ts-tp zamanları) meydana gelen depremlerdir**.** Şekil 4.19'da ve Şekil 4.20'de sırasıyla sadece ***r***=4 ***v***=2 parametre kombinasyonu tarafından tespit edilen 31 depremden seçilen uzak ve yakın deprem dalga formu örnekleri verilmiştir. Şekil 4.19 ve Şekil 4.20'de verilen depremler dalga formu benzerliklerine göre gruplandırılmıştır. Görüldüğü üzere aynı gün içinde veya diğer bir günde meydana gelen depremler aynı istasyonda neredeyse aynı dalga formları olarak görülmektedir.

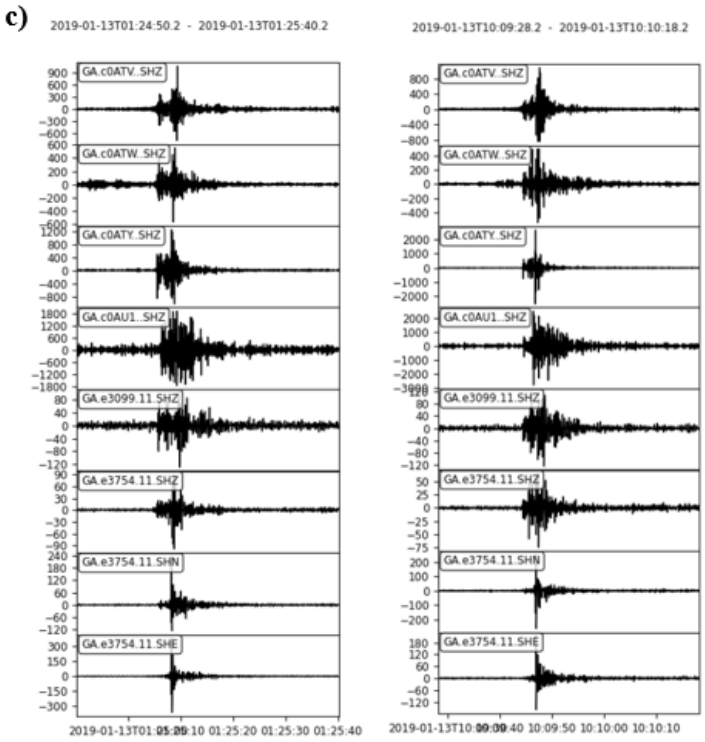




Şekil 4.19: Sadece *r*=4 *v*=2 parametreleri tarafından tespit edilen uzak deprem dalga formları örnekleri.


a)
2019-01-31T14:51:12.2 - 2019-01-31T14:52:02.2
2019-01-13T10:09:28.2 - 2019-01-13T10:10:18.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-31T14:51:30 14:51:40 14:51:50 14:52:00
2019-01-13T10:09:40 10:09:50 10:10:00 10:10:10


b)
2019-01-31T13:14:58.2 - 2019-01-31T13:15:48.2
2019-01-31T13:22:37.2 - 2019-01-31T13:23:27.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-31T13:15:10 13:15:20 13:15:30 13:15:40
2019-01-31T13:23:00 13:23:10 13:23:20



Şekil 4.20: Sadece *r*=4 *v*=2 parametreleri tarafından tespit edilen yakın deprem dalga formu örnekleri.

Tablo 4.19: 2019.01.01-2019.01.31 tarihleri arasında meydana gelen depremler ve algılama yöntemleri.

No	DEPREM	ENLEM	BOYLAM	DERİNLİK	BÜYÜKLÜK	KATALOG	STA/LTA	FAST	MANUEL
1	20190101031100	-	-	-	-	-	+	-	
2	20190101081858	39.6052	26.0100	6.8	2.3	+	+	-	
3	20190102005100	-	-	-	-	-	-	-	+
4	20190102051833	40.0250	27.6480	7.6	2.0	+	+	+	
5	20190102183337	-	-	-	-	-	+	+	
6	20190103012141	-	-	-	-	-	+	-	
7	20190103022249	-	-	-	-	-	+	+	
8	20190103034154	38.8345	26.4545	10.7	2.2	+	+	+	
9	20190103034745	40.2703	27.2705	11.9	2.9	+	+	+	
10	20190103040419	38.8428	26.4368	7.4	2.4	+	+	+	
11	20190103072948	39.5502	27.0877	7.6	1.8	+	-	-	+
12	20190103125116	-	-	-	-	-	+	+	
13	20190103134315	40.7315	27.5560	23.2	2.0	+	+	+	
14	20190103162715	39.5097	26.1643	5.6	3.6	+	-	-	+
15	20190104084738	40.6010	28.9900	5.0	2.8	+	+	+	
16	20190104120937	41.07	28.67	7	2.1	+	+	-	
17	20190104230111	39.5772	25.9962	5.4	2.3	+	-	-	+
18	20190105041858	40.4447	28.3713	10.4	4.1	+	+	+	
19	20190105124141	40.78	27.42	7	2.1	+	+	+	
20	20190105163113	40.7485	27.3587	3.3	1.9	+	+	+	
21	20190105202900	38.7260	27.9262	5.3	2.6	+	+	-	
22	20190105233500	38.8900	26.4402	8.0	2.0	+	+	-	
23	20190106002116	40.7150	27.8188	10.2	1.7	+	+	-	
24	20190106081225	40.6157	27.7132	7.7	1.5	+	+	-	
25	20190106082525	39.6032	26.4628	5.4	1.6	+	+	-	
26	20190106092353	40.7580	25.7250	9.1	2.1	+	+	-	
27	20190106131255	-	-	-	-	-	+	-	
28	20190106133930	-	-	-	-	-	+	-	
29	20190106150449	38.8602	26.4357	7.9	2.3	+	-	-	+
30	20190106194200	38.8602	26.4357	7.9	2.3	+	-	-	+
31	20190106212240	-	-	-	-	+	+	-	
32	20190107014946	40.6167	28.9703	9.2	1.8	-	+	-	
33	20190107122900	-	-	-	-	-	+	-	
34	20190107141723	-	-	-	-	-	+	-	
35	20190107171044	-	-	-	-	-	+	-	
36	20190107195320	38.86307	26.0208	6.1	2.3	+	-	-	+
37	20190107231000	38.4157	26.5865	16.3	3.3	+	+	-	
38	20190108035445	40.4015	27.4067	5.9	2.3	+	+	-	
39	20190108060052	38.8903	27.7480	5.2	2.7	+	+	-	

Tablo 4.19 (devam):

40	20190108100752	-	-	-	-	-	+	-	
41	20190108122821	-	-	-	-	-	+	-	
42	20190108205031	39.0288	26.2240	8.2	2.4	+	+	-	
43	20190108214441	-	-	-	-	-	+	-	
44	20190108224710	39.3713	26.0160	11.3	1.8	+	+	-	
45	20190109070020	40.8107	28.7587	23.3	2.0	+	-	-	+
46	20190109070900	40.6075	28.9912	5.1	2.3	+	+	+	
47	20190109075001	37.61	38.47	7	2.3	+	+	-	
48	20190109104600	37.3038	28.0722	10.0	1.8	+	+	-	
49	20190109113545	45.57	26.60	129	4.2	+	+	-	
50	20190109115626	-	-	-	-	-	+	-	
51	20190109120400	-	-	-	-	-	+	-	
52	20190109181022	-	-	-	-	-	+	-	
53	20190109181934	39.1610	26.0243	6.8	2.3	+	-	-	+
54	20190109184800	40.6027	28.9710	6.3	2.1	+	+	+	
55	20190109205600	-	-	-	-	-	+	-	
56	20190110063737	39.5103	26.1618	5.7	2.6	+	+	-	
57	20190110095800	-	-	-	-	-	+	-	
58	20190110215920	40.4043	27.4037	7.7	2.4	+	+	+	
59	20190110232635	-	-	-	-	-	+	+	
60	20190111010420	38.8693	27.7993	7.1	2.8	+	+	+	
61	20190111014338	38.89	27.82	6	2.4	+	+	+	
62	20190111015748	40.1550	25.0702	1.2	3.5	+	+	-	
63	20190111122935	-	-	-	-	-	+	-	
64	20190111123300	38.8638	27.7878	7.4	2.5	+	+	+	
65	20190111130256	40.5945	28.9642	8.5	1.9	+	-	+	+
66	20190111141800	40.60	28.96	13	2.2	+	+	+	
67	20190111160850	40.2818	28.8565	5.2	3.9	+	+	-	
67	20190111161929	38.8508	27.7773	4.3	3.0	+	+	+	
68	20190111183217	-	-	-	-	-	+	-	
69	20190111192431	39.7722	25.6275	6.2	3.1	+	+	+	
70	20190111205424	37.70	37.41	7	2.1	+	+	+	
71	20190111225141	40.4488	28.3708	5.8	2.7	+	+	+	
72	20190111235029	-	-	-	-	-	+	-	
73	20190112001425	-	-	-	-	-	+	-	
74	20190112034300	-	-	-	-	-	+	+	
75	20190112185049	-	-	-	-	-	+	+	
76	20190112230152	-	-	-	-	-	+	-	
77	20190113011600	39.8103	26.3263	4.1	1.7	+	-	+	+
78	20190113013900	-	-	-	-	-	+	-	

Tablo 4.19 (devam):

79	20190113012335	-	-	-	-	-	+	+	
80	20190113092058	-	-	-	-	-	+	-	
81	20190113100814	-	-	-	-	-	+	+	
82	20190113105536	-	-	-	-	-	+	+	
83	20190113162136	-	-	-	-	-	+	+	
84	20190113174441	-	-	-	-	-	+	+	
85	20190113180100	-	-	-	-	-	+	-	
86	20190113203532	39.0928	26.0983	8.1	2.0	+	+	+	
87	20190113211345	40.6927	27.4455	12.0	1.8	+	+	+	
88	20190113233442	40.4545	26.3772	15.0	2.3	+	+	+	
89	20190114002514	-	-	-	-	-	+	-	
90	20190114002655	-	-	-	-	-	+	+	
91	20190114003321	-	-	-	-	-	+	+	
92	20190114013400	-	-	-	-	-	+	+	
93	20190114020047	-	-	-	-	-	+	-	
94	20190114035551	-	-	-	-	-	+	+	
95	20190114065839	39.36	25.61	3	3.7	+	+	+	
96	20190114071948	39.4155	25.5430	6.7	3.3	+	+	+	
97	20190114085725	38.8835	27.8048	8.3	2.5	+	+	+	
98	20190114090127	38.88	27.81	4	2.1	+	+	-	
99	20190114144100	-	-	-	-	-	-	-	+
100	20190114162319	37.9192	27.1213	6.8	3.5	+	+	-	
101	20190115011150	-	-	-	-	-	-	-	+
102	20190115001828	40.7642	27.4160	14.9	1.3	+	+	+	
103	20190115194125	39.06	27.78	5	3.1	+	+	-	
104	20190116083000	-	-	-	-	-	-	-	+
105	20190116154320	-	-	-	-	-	+	-	
106	20190116165250	-	-	-	-	-	+	-	
107	20190116180400	-	-	-	-	-	+	-	
108	20190116200723	38.8763	26.1927	8.2	2.4	+	+	-	
109	20190116225235	38.7592	27.7795	11.6	2.7	+	+	-	
110	20190117031057	-	-	-	-	-	+	-	
111	20190117032211	-	-	-	-	-	+	-	
112	20190117035854	-	-	-	-	-	+	-	
113	20190117042756	-	-	-	-	-	+	-	
114	20190117055426	-	-	-	-	-	+	-	
115	20190117110052	-	-	-	-	-	+	-	
116	20190117115133	40.6772	27.4790	6.2	1.8	+	+	-	
117	20190117232652	-	-	-	-	-	+	-	
118	20190118011957	-	-	-	-	-	+	-	

Tablo 4.19 (devam):

119	20190118023542	-	-	-	-	-	+	-	
120	20190118035134	-	-	-	-	-	+	-	
121	20190118041756	-	-	-	-	-	+	+	
122	20190118111636	40.6957	27.4807	16.2	2.9	+	+	+	
123	20190118120116	-	-	-	-	-	+	+	
124	20190118132712	38.83	28.06	7	2.2	+	-	-	+
125	20190118133230	-	-	-	-	-	+	+	
126	20190118164420	-	-	-	-	-	+	-	
127	20190118182100	-	-	-	-	-	+	+	
128	20190118182535	40.74	29.00	12	2.0	+	+	+	
129	20190118184322	-	-	-	-	-	+	+	
130	20190118190245	-	-	-	-	-	+	+	
131	20190118190500	-	-	-	-	-	+	-	
132	20190118211258	-	-	-	-	-	-	+	+
133	20190118223900	-	-	-	-	-	+	+	
134	20190119014757	-	-	-	-	-	+	+	
135	20190119043200	-	-	-	-	-	+	+	
136	20190119043435	-	-	-	-	-	+	+	
137	20190119043938	-	-	-	-	-	+	+	
138	20190119052200	-	-	-	-	-	+	+	
139	20190119052338	40.7650	28.9893	5.4	2.4	+	+	+	
140	20190119074443	-	-	-	-	-	+	+	
141	20190119075413	-	-	-	-	-	+	+	
142	20190119090410	-	-	-	-	-	+	+	
143	20190119123139	-	-	-	-	-	+	+	
144	20190119180726	27.4766	40.6566	7.0	1.3	-	+	+	
145	20190119183826	-	-	-	-	-	+	+	
146	20190119220052	-	-	-	-	-	+	-	
147	20190120043949	40.6917	27.4610	13.1	1.3	+	+	+	
148	20190120061739	-	-	-	-	-	+	-	
149	20190120103019	-	-	-	-	-	+	+	
150	20190120142100	39.2465	28.3432	2.3	2.1	+	-	+	+
151	20190120153921	-	-	-	-	-	+	-	
152	20190120195611	39.8813	25.8570	13.0	2.0	+	+	-	
153	20190120211155	38.4035	28.5570	4.7	1.3	+	+	-	
154	20190120234315	-	-	-	-	-	+	+	
155	20190120234826	-	-	-	-	-	+	-	
156	20190121025846	39.1892	27.7698	8.3	2.6	+	+	-	
157	20190121031200	38.9468	26.2040	9.5	2.3	+	-	-	+
158	20190121064817	39.1443	29.0477	7.3	1.9	+	+	-	

Tablo 4.19 (devam):

159	20190121070335	-	-	-	-	-	+	-	
160	20190121085947	-	-	-	-	+	+	+	
161	20190121123900	39.4080	28.5015	4.2	2.3	+	-	-	+
162	20190121154736	-	-	-	-	-	+	+	
163	20190121180112	40.4568	28.1043	12.1	2.6	-	+	-	
164	20190122011538	-	-	-	-	+	+	+	
165	20190122012253	40.3837	28.3055	4.6	2.8	+	+	+	
166	20190122075021	-	-	-	-	-	+	-	
167	20190122085957	-	-	-	-	-	+	-	
168	20190122093816	-	-	-	-	+	+	-	
169	20190122180957	39.6998	27.8485	12.3	1.8	+	+	-	
170	20190123043717	39.8738	25.4977	6.2	2.5	+	+	+	
171	20190123064258	40.8213	27.9683	12.2	2.2	-	+	+	
172	20190123083013	-	-	-	-	-	+	+	
173	20190123120246	-	-	-	-	-	+	+	
174	20190123172500	-	-	-	-	-	+	+	
175	20190123191206	38.8932	27.8590	12.3	2.8	+	+	-	
176	20190124000421	-	-	-	-	-	-	-	+
177	20190124133317	-	-	-	-	-	+	+	
178	20190124140500	39.2757	29.2267	5.0	2.9	+	+	+	
179	20190124172617	40.6855	27.4667	11.3	1.9	+	+	+	
180	20190124221800	-	-	-	-	-	+	-	
181	20190125002320	-	-	-	-	-	+	+	
182	20190125042200	39.5990	28.0737	2.0	3.1	+	+	-	
183	20190125042929	39.4272	25.5483	9.6	3.3	+	+	+	
184	20190125044245	40.3872	26.9253	11.9	1.6	+	+	+	
185	20190125094541	-	-	-	-	-	+	-	
186	20190125201910	38.5823	27.1012	16.0	4.4	+	+	+	
187	20190126065314	-	-	-	-	-	+	-	
188	20190126135952	-	-	-	-	-	+	+	
189	20190126215000	-	-	-	-	-	+	+	
190	20190127000647	39.9623	28.0508	6.1	1.6	+	+	+	
191	20190127012100	-	-	-	-	-	+	+	
192	20190127022953	39.5792	26.0652	2.5	2.0	+	+	-	
193	20190127024030	40.6317	27.5488	24.2	1.6	+	+	+	
194	20190127031225	-	-	-	-	-	+	+	
195	20190127031442	39.0222	27.7567	12.8	4.3	+	+	-	
196	20190127031500	38.5815	27.0938	7.0	4.0	+	+	+	
197	20190127031558	-	-	-	-	-	+	-	
198	20190127042200	-	-	-	-	-	+	+	

Tablo 4.19 (devam):

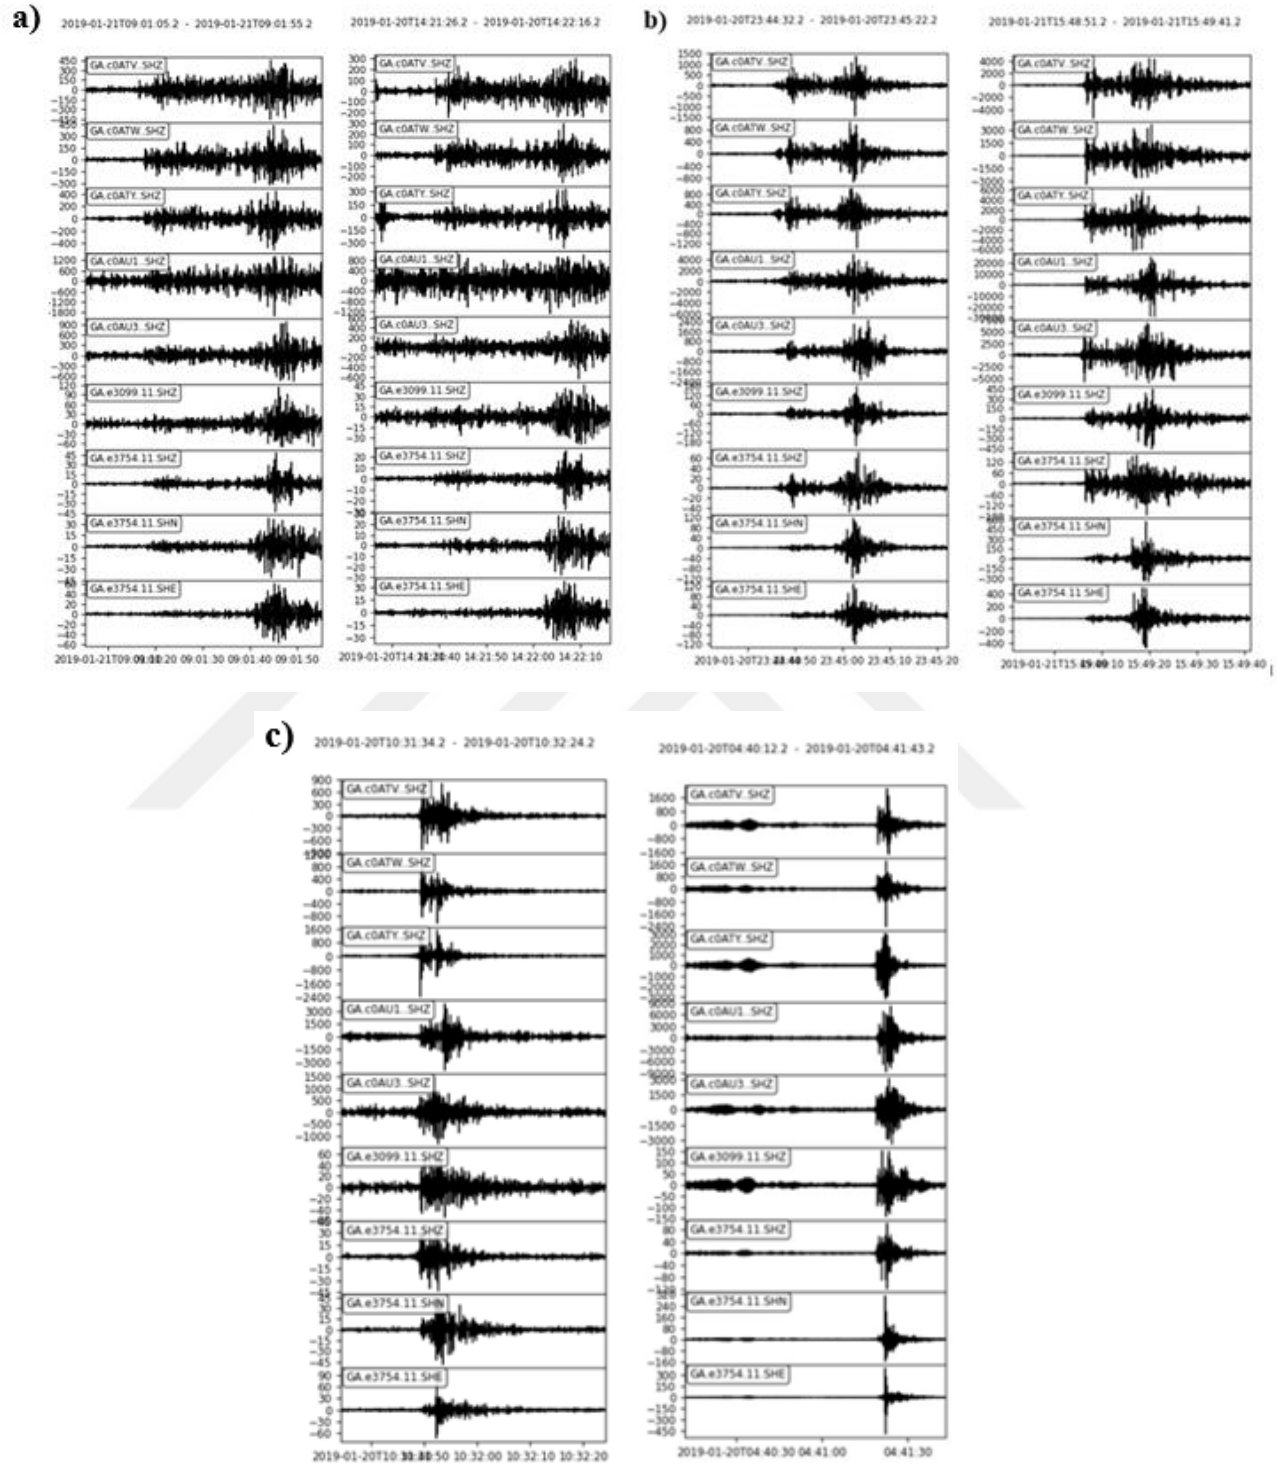
199	20190127045643	39.0347	27.7767	7.5	2.0	+	+	-	
200	20190127085947	38.9793	26.4272	12.5	2.5	+	+	+	
201	20190127101600	-	-	-	-	-	+	+	
202	20190127120140	38.8457	26.4255	7.5	2.2	+	+	-	
203	20190127123400	39.8288	27.9590	14.1	1.5	+	+	-	
204	20190127170428	41.6353	26.5293	6.1	1.2	+	+	-	
205	20190127175000	-	-	-	-	-	+	-	
206	20190127192100	39.5355	25.9977	6.1	2.0	+	-	-	+
207	20190127204229	-	-	-	-	-	+	-	
208	20190127210300	39.0403	27.7818	7.3	2.1	+	-	-	+
209	20190127221800	-	-	-	-	-	+	-	
210	20190128074933	39.4797	26.1380	5.5	2.3	+	+	+	
211	20190128082100	39.4093	26.2298	12.0	1.5	+	-	+	+
212	20190128082420	-	-	-	-	-	+	+	
213	20190128083011	-	-	-	-	-	+	+	
214	20190128094157	-	-	-	-	-	+	+	
215	20190128133756	-	-	-	-	-	+	+	
216	20190128165733	39.4410	26.1915	5.3	3.5	+	+	+	
217	20190128171400	-	-	-	-	-	-	+	+
218	20190128175225	39.4412	26.1595	5.1	2.0	+	+	+	
219	20190128180020	39.4633	26.0745	1.9	1.9	+	+	+	
220	20190128182349	39.4452	26.0948	5.0	1.8	+	+	+	
221	20190128184417	39.4092	27.8683	8.4	2.3	+	+	-	
222	20190128195816	39.6122	26.4350	5.9	1.9	+	+	+	
223	20190128213918	-	-	-	-	-	+	+	
224	20190129005822	39.4222	25.9740	9.2	2.4	+	+	-	
225	201901290147	39.4827	26.1222	8.0	2.2	+	+	+	
226	20190129021255	-	-	-	-	-	+	-	
227	20190129023152	-	-	-	-	-	+	+	
228	201901290253	-	-	-	-	-	+	+	
229	20190129105827	-	-	-	-	-	+	-	
230	20190129174734	-	-	-	-	-	-	-	+
231	20190129181727	-	-	-	-	-	+	+	
232	20190129181853	-	-	-	-	-	+	+	
233	20190129201841	39.5582	26.1753	6.3	2.2	+	+	+	
234	201901292321	-	-	-	-	-	+	-	
235	20190129234939	-	-	-	-	-	+	+	
236	20190129235855	39.4507	26.1538	8.1	2.3	+	+	-	
237	201901300153	39.7838	27.9068	5.4	2.1	+	+	+	
238	20190130020435	39.5312	26.1748	7.7	2.5	+	+	+	

Tablo 4.19 (devam):

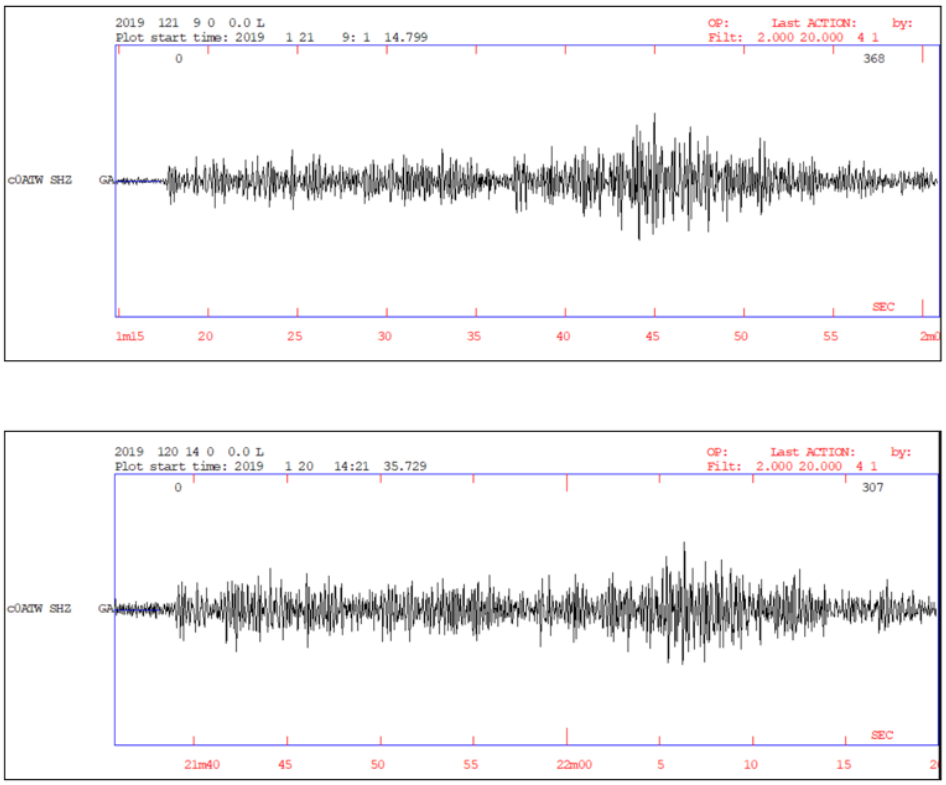
239	20190130035958	-	-	-	-	-	+	-	
240	20190130040830	40.3633	28.6313	13.0	1.5	+	+	-	
241	20190130050614	-	-	-	-	-	+	+	
242	20190130111114	40.4530	26.9358	9.9	1.5	+	+	+	
243	20190130124732	39.1353	27.0223	8.3	2.2	+	-	-	+
244	20190130132031	-	-	-	-	-	+	-	
245	20190130145512	39.5853	26.1198	6.8	1.9	+	+	-	
246	20190130162321	-	-	-	-	-	+	-	
247	20190130165545	45.20	26.49	132	2.8	+	+	-	
248	20190130171457	-	-	-	-	-	+	+	
249	20190130184353	-	-	-	-	-	+	+	
250	20190130193100	40.8748	25.6765	6.1	1.6	+	+	-	
251	20190130202900	-	-	-	-	+	+	-	
252	20190130224340	-	-	-	-	-	+	-	
253	20190131044644	-	-	-	-	-	-	-	+
254	20190131051245	-	-	-	-	-	+	+	
255	20190131091059	39.1722	26.0325	13.2	2.8	+	+	-	
256	20190131112411	-	-	-	-	-	+	-	
257	20190131131341	-	-	-	-	-	+	+	
258	20190131132120	-	-	-	-	-	+	+	
259	20190131144953	-	-	-	-	-	+	+	
260	20190131173423	40.7113	27.4447	8.5	1.9	+	+	+	
261	20190131181228	-	-	-	-	-	+	-	
262	20190131203700	40.0352	27.4357	9.5	1.9	+	+	+	

Tablo 4.19'da 2019.01-01-2019.01.31 tarihleri arasında STA/LTA yöntemi ile yapılan ayıklama sonucunda elde edilen depremler verilmektedir. Tablo 4.19'da 2019.01.20-2019.01.21 tarihlerinde (iki günlük veri) toplam 14 depremin STA/LTA yöntemiyle algılandığı görülürken FAST algoritmasının Tablo 4.19'da verilen depremlerden 6'sını algıladığı görülmektedir. Verilen bu 6 depremden 2019.01.20 tarihinde saat 14:21:26.2'de istasyonlar tarafından kaydedilen deprem haricindeki diğer depremler STA/LTA yöntemiyle tespit edilmiştir. Şekil 4.21'de FAST tarafından algılanan 6 deprem dalga formu benzerliklerine göre gruplandırılmıştır. Gruplandırılan depremlerin aynı istasyonlarda benzer dalga formlarına sahip oldukları açıkça görülmektedir. Tablo 4.12'de verildiği üzere algılama için 7 istasyondan en az 4'ünde benzer olayların olması gerekmektedir. Buna göre Şekil 4.21a ve Şekil 4.21c'de verilen depremler 7 istasyonun tamamında benzer dalga formlarına sahipken Şekil 4.21b'de verilen depremler sırasıyla 5 ve 6 istasyonda benzer dalga formlarına sahiptirler. Şekil 4.22'de Şekil 4.21a'da verilen her iki depremin c0ATW istasyonu düşey bileşen kaydı alt alta verilmiştir. Görüldüğü üzere dalga formlarının benzerliği açıkça görülmektedir. Kataloglarda yapılan tarama da depremlerin meydana geldikleri lokasyonlara bakıldığında a ve b grubundaki

depremlerin Balıkkesir civarında meydana gelen depremler oldukları görülürken, c grubunda verilen Tekirdağ-Güzelköy açıklarında meydana gelen depremler oldukları belirlenmiştir.

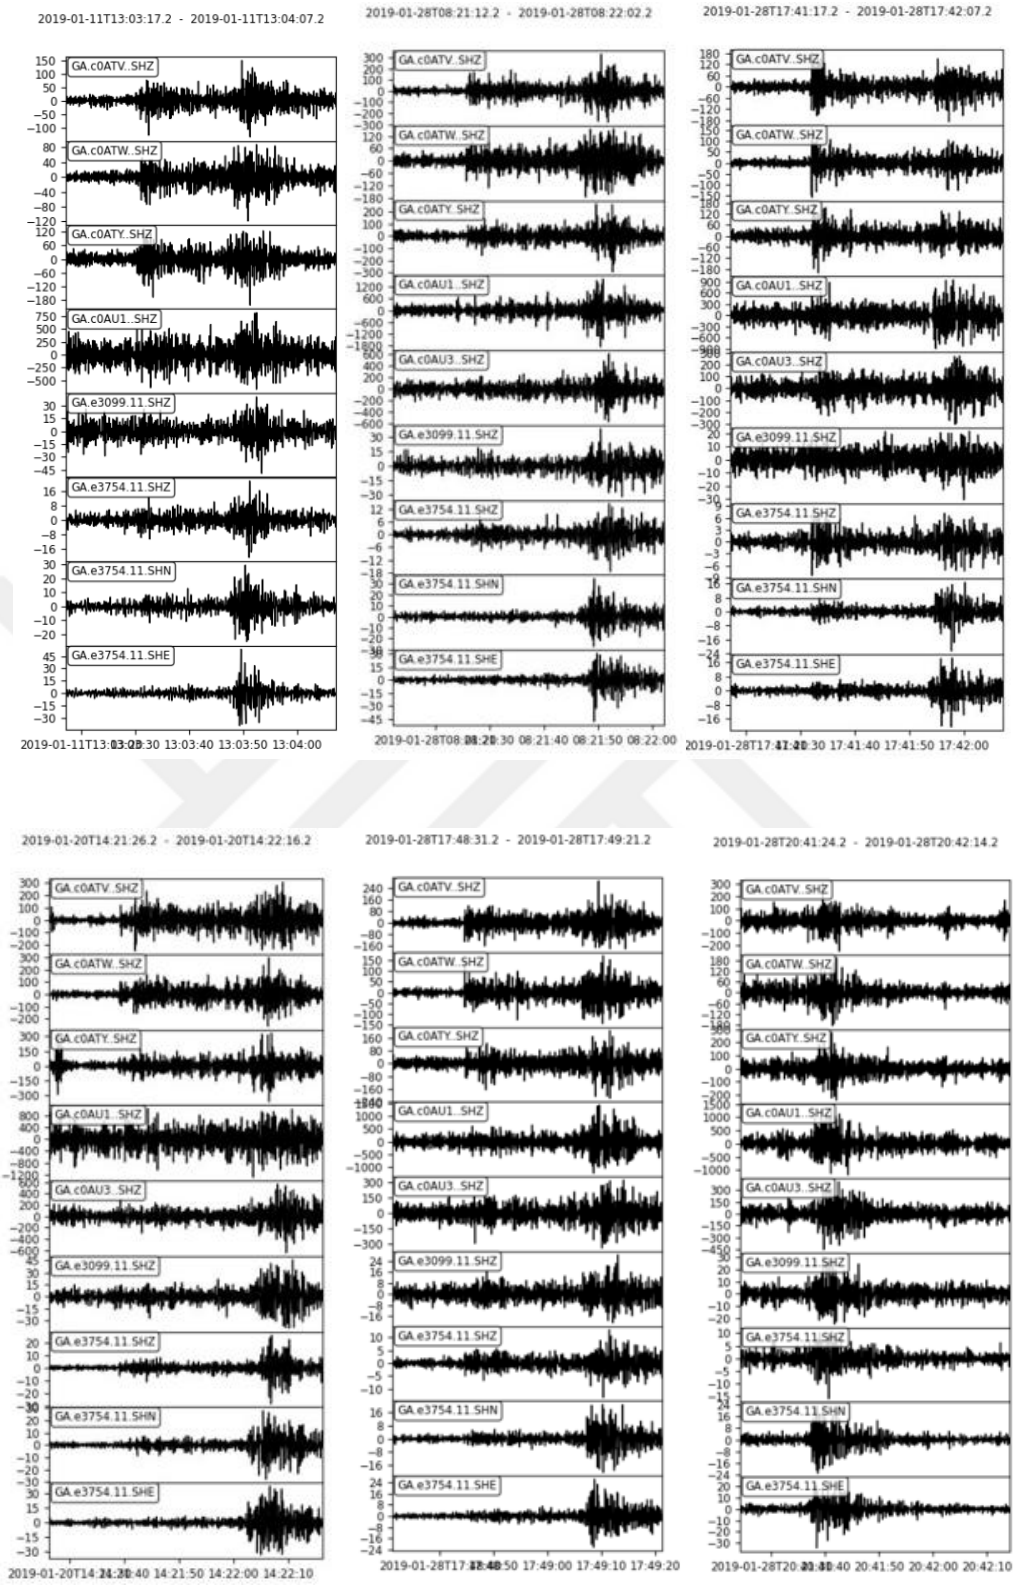


Şekil 4.21:2019.01.20-2019.01.21 tarihlerinde FAST tarafından algılanan depremlerin dalga formları.



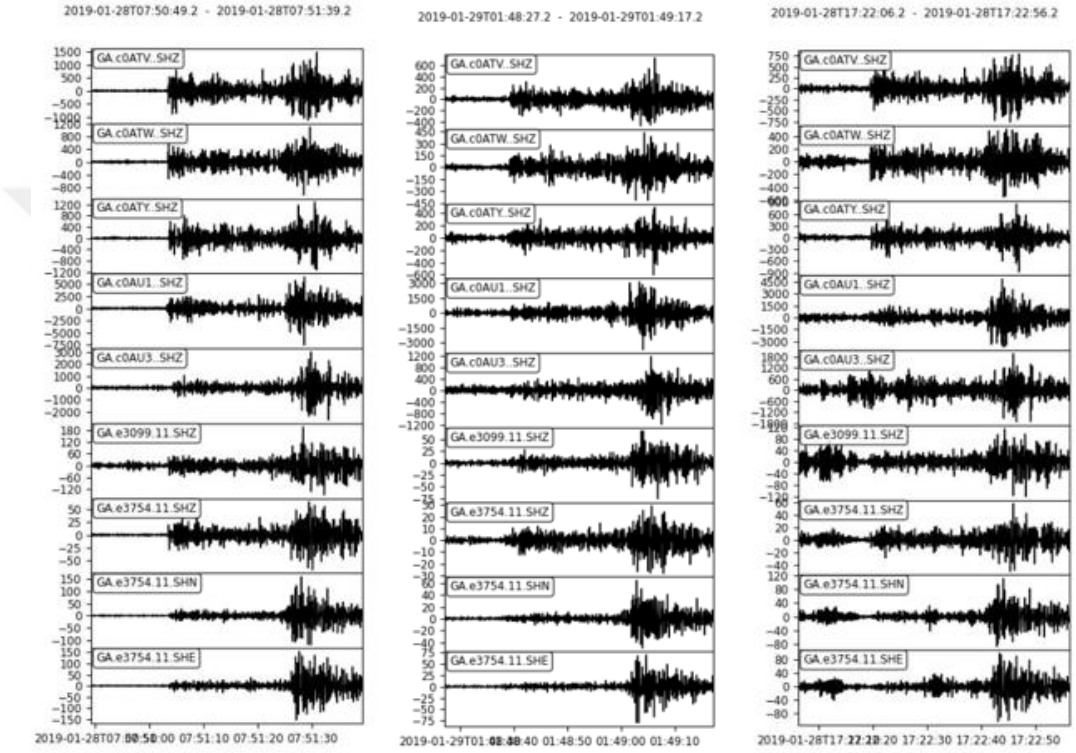
Şekil 4.22: Şekil 4.21a'da verilen iki depreme ait c0ATW istasyonu düşey bileşen kaydı.

Şekil 4.23'te bir aylık süre içinde STA/LTA tarafından tespit edilemeyen ancak FAST tarafından tespit edilebilen 6 depremin dalga formu verilmektedir. Ulusal kataloglarda yapılan taramada Şekil 4.23'te verilen depremlerin kataloglarda yer alan uzak depremler oldukları tespit edilmiştir. Görüldüğü üzere FAST, STA/LTA yönteminin tespit edemediği gürültü içinde yer alan depremleri tespit edebilmiştir. Yakın depremlerin ise hem FAST hem de STA/LTA yöntemi ile tespit edilebildiği belirlenmiştir.

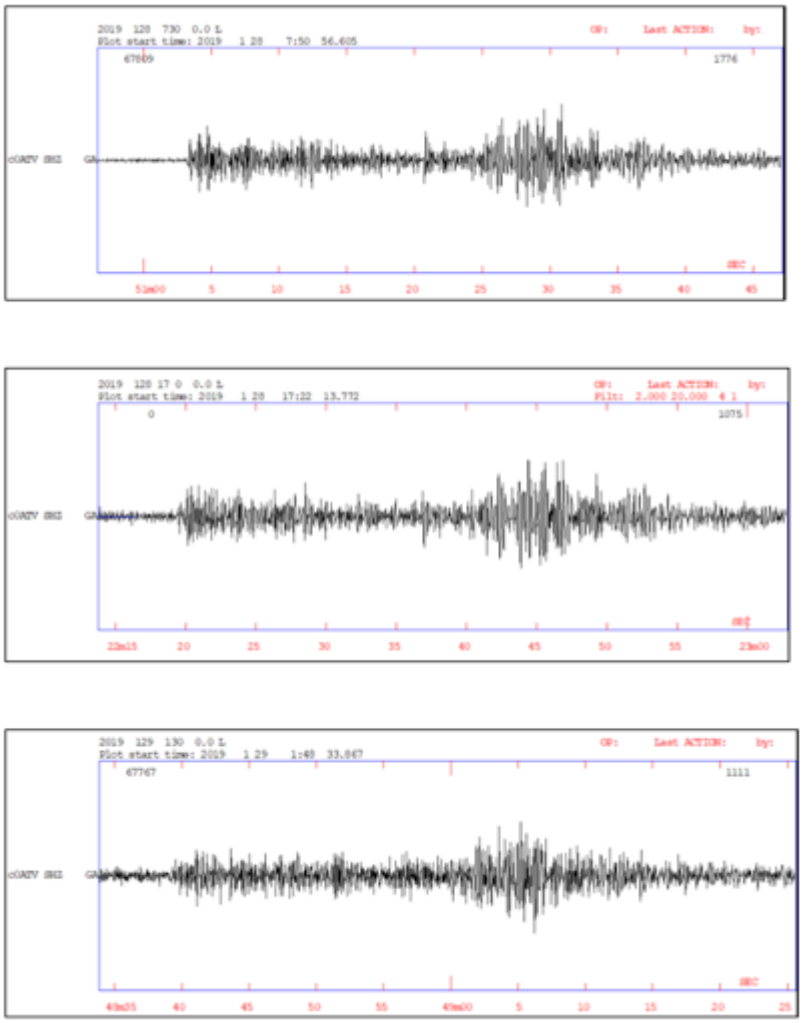


Şekil 4.23: STA/LTA tarafından tespit edilmeyen fakat FAST tarafından algılanan uzak depremler.

Şekil 4.24'te 2019.01.28-2019.01.29 tarihlerinde FAST tarafından tespit edilen benzer deprem dalga formuna sahip uzak deprem kaydı örnekleri verilmiştir. Ulusal kataloglarda yapılan tarama da her üç depremin Çanakkale-Ayvacık'ta meydana gelen ve büyüklükleri sırasıyla 2.3 ve 2.2, 2.2 olan uzak depremler oldukları görülmüştür. Şekil 4.25'te her üç depremin verilen c0ATV istasyonu düşey bileşen kaydında dalga formlarının benzerliği açıkça görülmektedir.

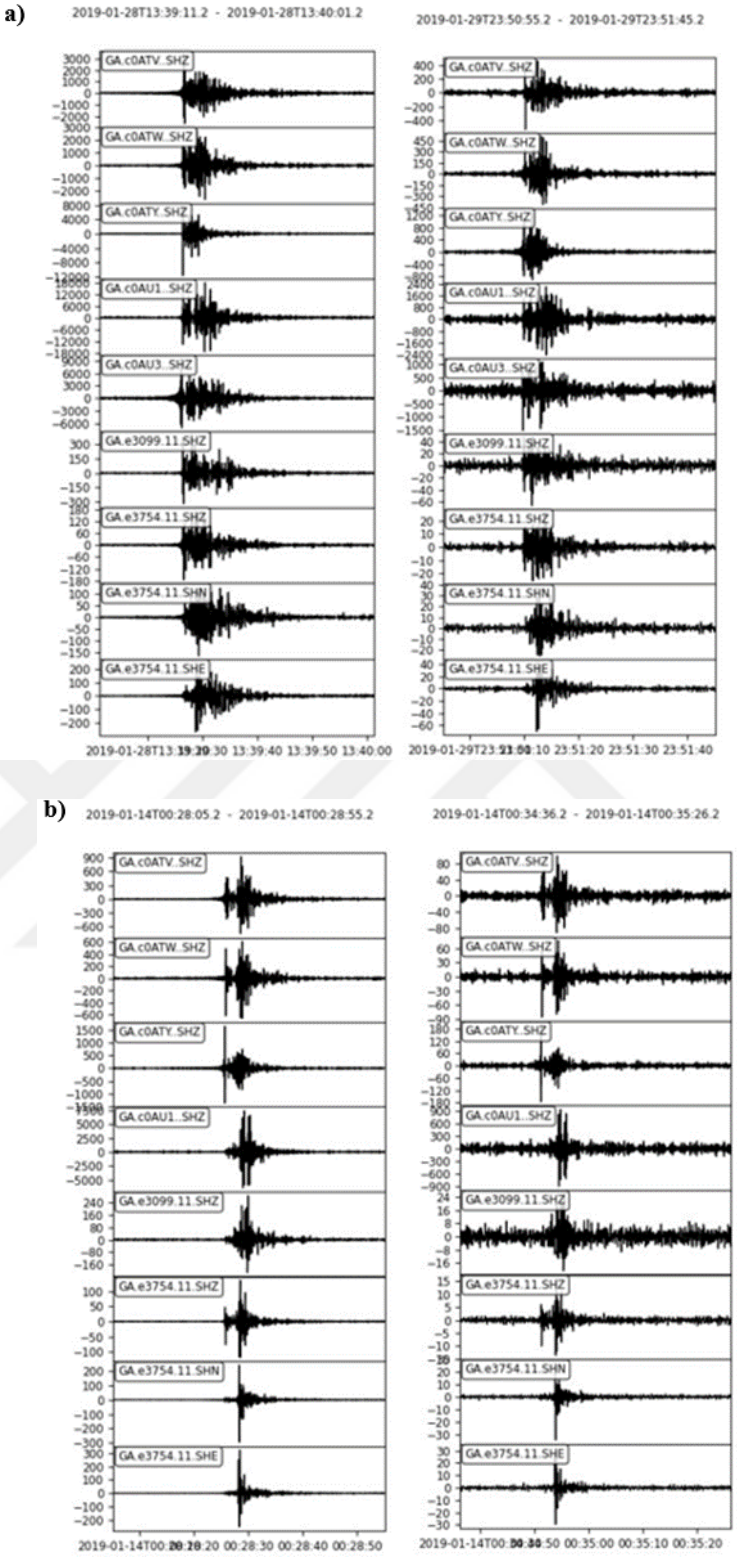


Şekil 4.24: 2019.01.28-2019.01.29 tarihlerinde FAST tarafından algılanan uzak deprem kaydı örnekleri.

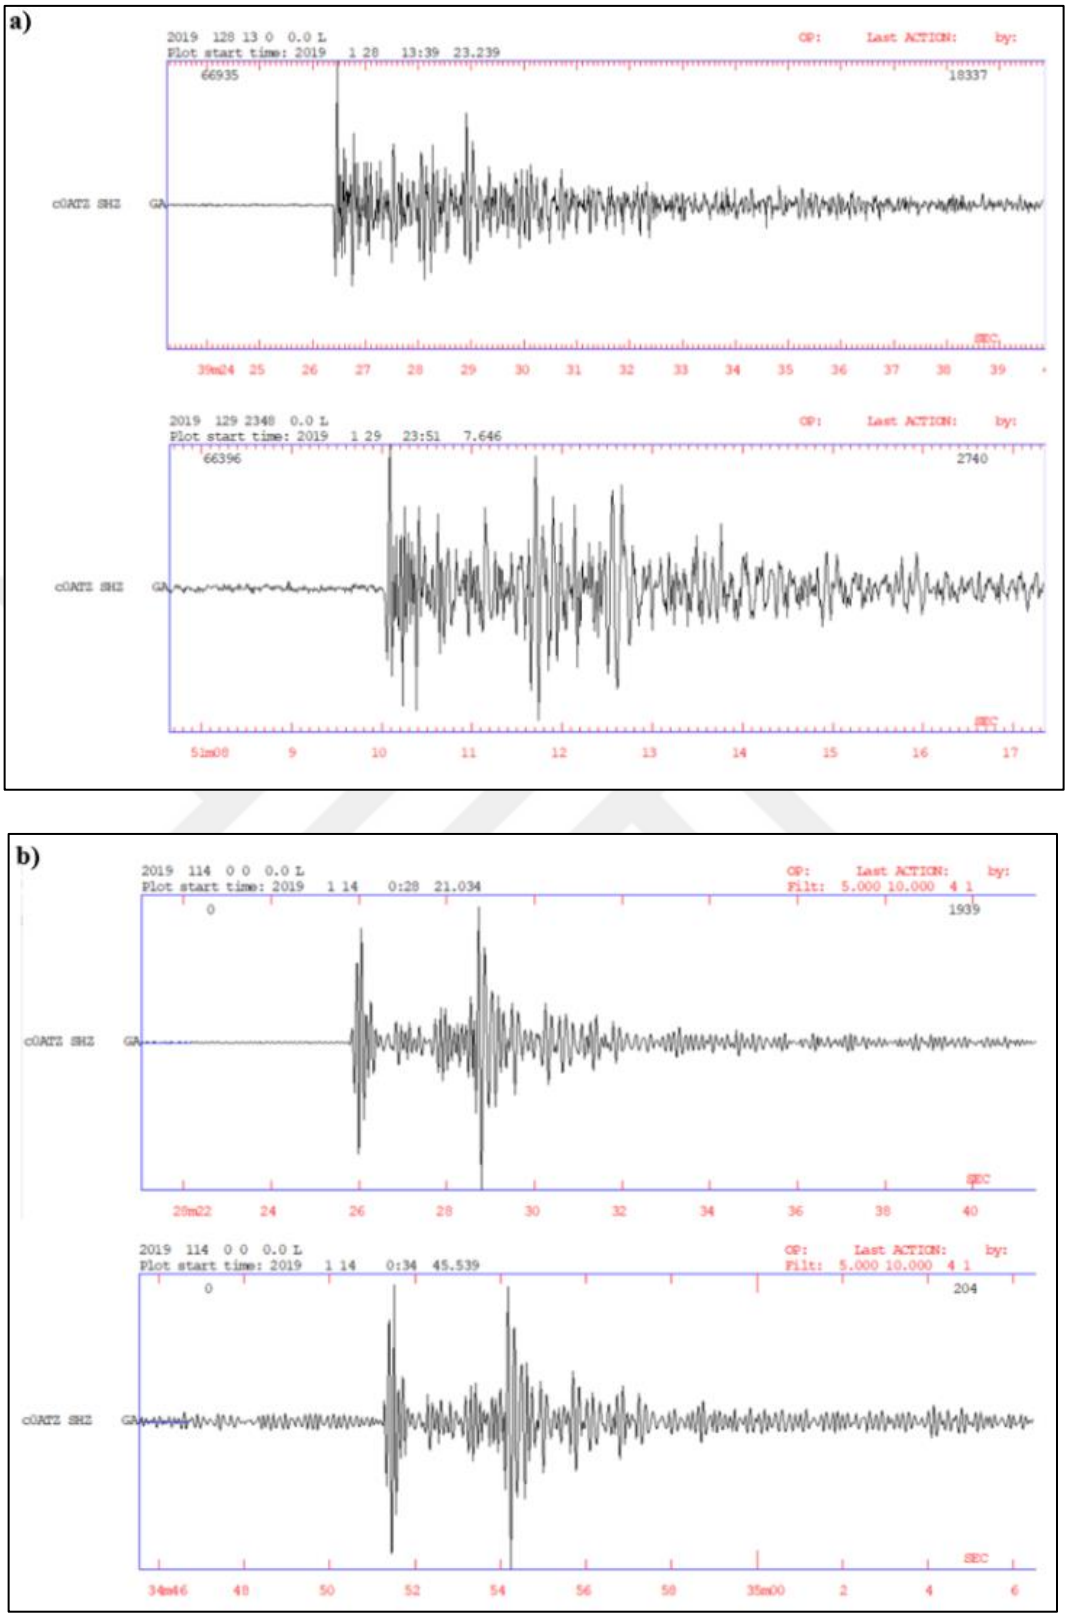


Şekil 4.25: Şekil 4.24'te verilen depremlerin c0ATV istasyonu düşey bileşen kaydı.

Şekil 4.26'da FAST tarafından tespit edilen kataloglarda yer almayan yakın deprem dalga formu örnekleri verilmiştir. Depremlerin istasyonlara yakın meydana gelen depremler olması nedeniyle ulusal kataloglarda yer almamaktadır. Şekil 4.27'de istasyonlara ait düşey bileşen kayıtlarında dalga formlarının benzer olduğu açıkça görülmektedir.



Şekil 4.26: FAST tarafından algılanan kataloglarda olmayan yakın deprem dalga formu örnekleri. a)2019.01.28 tarihinde saat 13:39:11.2 ve 2019.01.29 tarihinde saat 23:50:55.2 'de istasyonlara tarafından kaydedilen benzer deprem dalga formuna sahip depremler. b) 2019.01.14 tarihinde saat 00:28:05.2 ve 2019.01.14 tarihinde saat 00:34:36.2 'de istasyonlara tarafından kaydedilen benzer deprem dalga formuna sahip depremler.



Şekil 4.27: Şekil 4.26'da verilen depremlerin c0ATV istasyonu düşey bileşen kaydı. a)2019.01.28 tarihinde saat 13:39:11.2 ve 2019.01.29 tarihinde saat 23:50:55.2 'de istasyonlara tarafından kaydedilen benzer deprem dalga formuna sahip depremlerin c0ATZ düşey bileşen kaydı. b) 2019.01.14 tarihinde saat 00:28:05.2 ve 2019.01.14 tarihinde saat 00:34:36.2 'de istasyonlara tarafından kaydedilen benzer deprem dalga formuna sahip depremlerin c0ATZ düşey bileşen kaydı.

5. TARTIŞMA VE SONUÇ

Bu tez kapsamında 2017-2020 tarihleri arasında Ganos Fayı üzerinde çalıştırılan 40 istasyondan oluşan MONGAN deprem izleme ağından toplanan bir aylık sürekli verileri içerdikleri deprem sayısı ve benzer depremlerin bulunması amacıyla işlenmesi planlanmıştır. Amacımız bu veriler üzerinde deprem ayıklama yöntemlerinden olan STA/LTA ve FAST algoritmalarını uygulayarak veriler için en iyi sonucu verecek olan algoritma ve parametreleri ortaya koyabilmektir. Kullanılan algoritmaların zayıf ve güçlü yönlerini tartışabilmektir.

Günümüzde üç bileşenli sensöre sahip farklı sismik ağlarda yıllarca süren sürekli sismik veri akışları kaydedilmektedir. Artan istasyon sayısıyla yüksek miktarda veri setleri ortaya çıkmaktadır. Bu veriler büyük oranda deprem kataloglarında eksik olan küçük depremlerden kaynaklanan zayıf sinyaller içermektedir. Bu küçük depremlerin keşfi lokal sismisitenin anlaşılması açısından son derece önemlidir.

Bilindiği üzere STA/LTA dedektörleri impulsive depremleri (P ve S varışlarındaki yüksek sinyal gürültü oranı) başarılı şekilde tanımlayabilirken, düşük sinyal/gürültü (S/N) oranlarında, yumuşak (emergent) dalga fazı başlangıçlarında, örtüşen olaylarda, kültürel gürültü, seyrek istasyon aralığı gibi değişen durumlarda depremleri algılayamaz veya yanlış tetiklenmeler üretebilmektedirler. Bu açıdan STA/LTA dedektörleri nispeten düşük algılama hassasiyetine sahiptir. Bu yüzden düşük magnitüdlü olaylar deprem kataloglarında eksiktir. FAST algoritması ile impulsive P ve S dalga varışlarından ziyade, algılama için deprem dalga formunun tamamından gelen bilgileri kullanarak, STA/LTA yöntemine ek olarak, özellikle gürültü içinde kalan benzer dalga formlarından deprem keşiflerine ek bilgi sağlaması hedeflenmiştir.

Bu tez çalışmasında STA/LTA yöntemi kullanarak yapılan otomatik ayıklama işlemine tabi tutulan bir aylık sürekli veri ile manuel ayıklama arasında, kullanılan parametre değerlerine bağlı olarak %32 ile %51arasında değişen farklılıklar ortaya çıkmıştır. Bunların bir kısmı otomatik ayıklamanın yakalamadığı olayların eklenmesi şeklinde iken, diğer kısmı ise yanlış tetikleme nedeniyle olay silme şeklindedir. Yapılan ekleme ve silme işlemlerinin sonucunda çalışılan süre içinde tespit edilen net olay sayısı 262'dir. STA/LTA yönteminde en yüksek hatalar daha uzun pencere süreleri (STA=0.5 s, LTA=60 s) ile yapılan algılamada ortaya çıkmıştır (%51.65). Daha düşük hatalar ise (%32.04) kullanılan daha kısa pencere süreleri ile

(STA=0.3 s, LTA=30 s) elde edilebilmiştir. STA/LTA yöntemi kullanılarak hatalı tespit edilen olaylardan önemli bir kısmı deprem olmayan (patlatma veya yüksek enerjiye sahip endüstriyel faaliyetler) kayıt formlarıdır. Bu sonuçtaki önemli etkenlerden biri kullanılan MONGAN sismik ağında istasyonlar arası mesafelerin oldukça küçük olmasıdır (25m-4km). Bu durumda lokal-endüstriyel sinyaller birden fazla istasyonda yaklaşık aynı zamanda kaydedilebilmekte ve ortaya çıkan yüksek ve keskin genlikler STA/LTA yöntemiyle deprem olarak algılanabilmektedir. Diğer hatalı keşif nedenleri arasında; uzun süreli depremlerde ikinci bir tetiklenme (P ve S tetiklenmeleri), farklı frekans aralıklarında çevresel gürültülerin sinyal enerjisini gölgelemesi, mevsimsel ve hava şartları nedeniyle ortaya çıkan enerji formları sayılabilir. Bu tip hatalı keşifler ancak tecrübeli bir operatörün manuel kontrolü sırasında farkedilebilmektedir. Eğer kayıt formları deprem dalga formlarıyla çok benzer ise manuel kontrol ötesinde farklı veri analiz yöntemleri (örneğin spektral içerikler) devreye alınması gerekir. STA/LTA dedektörü tarafından yeterli enerjiye sahip yakın depremlerin rahatlıkla tespit edilebildiği görülmüştür. STA/LTA tarafından kaçırılan depremlere bakıldığında önemli bir kısmının uzak depremler olduğu görülmüştür. Ancak bu depremler kullanılan farklı STA/LTA parametre değerleri ile yapılan otomatik ayıklamada keşfedilebilmişlerdir. STA ve LTA pencere süreleri artırılarak uzak depremlere karşı daha hassas hale getirilebilir. STA/LTA operatörünü kaçırılan depremlere uygun parametre seçimiyle oluşturmak mümkün olabilir, fakat bu kez de hatalı deprem sayısı çok arttırılmış olur. Amaç optimum parametreler ile en az hata oranı ile ayıklama işleminin yapılması gerekmektedir. Bu tez çalışmasında STA=0.3 sn ve LTA=30 sn ile yapılan otomatik ayıklamada en az hata oranına erişilmiştir. Bu açıdan en uygun parametre değerinin bu pencere sürelerine ait olduğunu söyleyebiliriz. Bu pencere süreleri ile yapılan otomatik ayıklamada 262 depremden 75‘nin yakın, 187’si uzak depremlerden oluşmaktadır. 262 depremin 124 tanesi ulusal kataloglarda yer alırken 138’i kataloglarda yer almamaktadır. Katalogda yer alan depremlerin büyüklükleri $1.1<M_l<4.3$ arasında değişmektedir.

Bu tez kapsamında kullanılan FAST algoritması benzer kaynaklara sahip depremlerin benzer deprem dalga formları üretme eğiliminde olduğu gözlemine dayanan, algılama için temel olarak benzerliği kullanan bir dedektördür. FAST’in tipik kullanım durumu, bir araştırmacının birkaç sismik istasyonda mevcut bir sürekli veri koleksiyonuna sahip olması, depremler veya olası şablon olayları hakkında önceden bilgi sahibi olmaması ve küçük yerel depremleri aramak istemesidir.

Bu tez çalışmasında FAST algoritmasını çalıştırmak amacıyla sanal bir bilgisayar üzerinde 9 GB RAM'a sahip bir Linux işletim sistemi kurulmuştur. Ancak FAST için Linux işletim sisteminde en az 64 GB RAM gerekmektedir (Yoon ve diğ.,2015). Bu durum karşısında bir aylık sürekli veri, 2 günlük bölümler halinde çalıştırılabilmiştir. 2 günlük veriler halinde çalıştırıldığında elde edilen benzer deprem sayısının, bir aylık veri ile çalışıldığında ele edilen benzer deprem sayısından çok daha az olacağı açıktır. Çünkü benzer depremlerin iki günlük periyotlar içinde olması gerektiği gibi bir durum söz konusu değildir.

Tez çalışmasında FAST ile toplam bir aylık veri içinde, ikişer günlük periyotlar halinde benzer dalga formlarına sahip depremleri tespit etmek ve FAST 'in algılama yeteneğinin STA/LTA yöntemiyle elde edilen sonuçlara nasıl katkı yapabileceği araştırılmıştır. FAST ile yapılan farklı *r* ve *v* parametrelerine bağlı olarak elde edilen algılama sonuçlarına göre en fazla benzer dalga formuna sahip deprem sayısının elde edildiği kombinasyon olarak *r*=4 *v*=2 parametre değerleri olduğu ve diğer parametre kombinasyonları (*r*=4 *v*=3, *r*=4 *v*=4, *r*=5 *v*=2, *r*=5 *v*=3, *r*=5 *v*=4) tarafından tespit edilemeyen 31 depremi (bkz. **EK 2**) tespit ettiği belirlenmiştir. ***r***=4 ***v***=2 kombinasyonu ile yapılan FAST algılamada %92.51 ortalama hata yüzdesiyle en yüksek olay sayısı (1 aylık süre kapsamında 114 adet) elde edilmiştir. Diğer *r* ve *v* kombinasyonlarına kıyasla *r*=5 *v*=4 kombinasyonu ile yapılan FAST algılamada %79.41 en düşük ortalama hata yüzdesiyle en az olay sayısı (47 adet) elde edilmiştir. Yapılan katalog taramasında 114 depremin 49'u katalog da yer alırken, 65'i katalogda bulunmamaktadır. Bunlardan 47'si yakın deprem iken (ts-tp <3 sn) 67 'si uzak (ts-tp>4sn) depremlerdir. STA/LTA tarafından tespit edilemeyen gürültü içindeki 6 deprem benzerlik özelliği kullanılarak FAST tarafından tespit edilebilmiştir.

Bu tez çalışmasında bir aylık verinin alındığı bölge Ganos Fayı'nın kara segmentinde kurulan ve asismik kilitlenmiş davranış sergileyen Ganos Fayı'nın mikrosismik etkinliğinin görüntülendiği ve iki malzemeli fay yapısını fay zonu dalga analizleriyle incelemesinin amaçlandığı bir bölgedir. Yalçınkaya ve diğ. (2022) yaptığı çalışmada toplanan ilk 3 aylık veri STA/LTA yöntemi kullanarak otomatik ayıklama işlemine tabi tutulan sürekli veriler ile manuel ayıklama arasında %40-%50'ye varan farklılıklar ortaya çıkmıştır. Yöntem özellikle mikro depremlerin ayıklanmasında, düşük sinyal/gürültü oranları nedeniyle yeterli başarıya ulaşamamıştır. Manuel ayıklama sırasında farklı filtreler kullanarak, çok sayıda istasyon verisinin aynı anda kontrolü mikro depremlerin gözlenebilmesine imkân vermiştir. Fakat manuel ayıklamanın oldukça yorucu ve zaman alan bir yol olması nedeniyle, çalışmanın ileriki aşamalarında farklı algoritmaların denenmesi amaçlanmıştır. FAST algoritması düşük

sinyal/gürültü oranına sahip depremleri algılayabilmektedir. Bu tez çalışmasında yetersiz RAM'den kaynaklı olarak, verinin tümünün aynı anda çalıştırılamamasından dolayı FAST algoritması gerçek manada, verimli olarak kullanılamamıştır. Ancak uzun süreli veri seti ile FAST algoritmasının çalıştırılması halinde STA/LTA yönteminin kaçırdığı gürültü içinde kalan benzer depremlerin ayıklanmasının mümkün olacağı düşünülmektedir.

FAST ile yapılan çalışmalara bakıldığında kataloglarda yer almayan çok sayıda mikro depremlerin algılanabildiği görülmektedir. Örneğin; Yoon ve diğ., (2018) yaptığı çalışmada Kaliforniya'nın Hector Mine bölgesinde 1999 yılında büyüklüğü M_w=7.1 olan ana şok öncesi büyüklükleri -0.4<M<3.7 arasında değişen 50 öncü sarsıntıyı FAST benzerlik algılamasıyla keşfedilmişlerdir. Ana şokun oluşumu sürecinde mikro depremlerin algılanması önemli olmuştur.

FAST yüksek benzerliğe sahip herhangi bir dalga formu çiftini aday depremler olarak kabul ederek daha önceden bilinmeyen olayları belirleyebilir. Ancak bu, FAST'i yanlış algılamalara karşı da duyarlı hale getirir. Tüm benzer dalga formları çiftleri depremlere atfedilemez- benzer veya tekrarlayan dalga formları kalıcı yerel gürültü kaynaklarına da atfedilebilir. Tez çalışmasında FAST tarafından yanlış algılanan, deprem olmayan dalga formu örnekleri gözlenmiştir. Veri içindeki ilişkili (correlated) gürültüler nedeniyle benzer dalga formu çiftleri deprem olarak algılanmıştır. Bu algımalar nedeniyle genel olarak yapılan FAST sınamaları beklenenin çok üzerinde hatalarla sonuçlanmıştır. Bu sonuçtaki en önemli etkenlerden birinin istasyon ağının yapısı olduğu düşünülmektedir. Kullanılan ağ istasyonlarının birbirine çok yakın olması, ilişkili gürültü kayıtlarının (yerel gürültünün aynı anda birden çok istasyonda kaydedilmesi) çok sayıda olması sonucunu doğurmuştur. Daha uzak istasyon ağlarında FAST'in kullanılmasının, daha verimli sonuçlar üreteceği düşünülmektedir. Bu durumda ilişkili gürültü sayısı azalacaktır. Bu ilişkili gürültünün etkisini azaltmak için gürültülü dönemlerde daha yüksek bir algılama eşiği uygulanarak, benzer gürültü sinyallerinden benzer sismik sinyalleri ayıracak şekilde gruplandırılabilir ve depremleri gürültüden ayıran özellik sınıflandırıcıları gibi son işleme algoritmaları geliştirilebilinir. Bir diğer yöntem ilişkili gürültüleri yok etmekte uygun filtreler kullanılması olacaktır. Bu çalışmada genel gürültü içeriği analiz edilerek uygun filtre tasarımı yapılamamıştır. Fakat ileriki çalışmalarda farklı filtre tasarımları denenebilir. Birincisi daha uzak kaynaklı ve düşük frekans içeriği açısından, diğeri ise daha yakın kaynaklı ve yüksek frekans içeriğine sahip gürültülerin yok edilmesi açısından filtreler oluşturulabilir.

Tez çalışmasının devamında planlanan bir diğer uygulama ağın farklı istasyonları kullanılarak yöntemin sınanmasıdır. Bu çalışmada belirtilen bir aylık süre içinde en az veri kaybına sahip istasyonlar çalışmaya dahil edilmiştir. Ancak farklı istasyon seçiminin, farklı gürültü içerikleri nedeniyle sonuçları önemli oranda değiştireceği açıktır.

FAST'in önemli avantajlarından biri, diğer benzer yöntemlere göre, örneğin şablon eşleştirme ya da otokorelasyon, çok daha hızlı analiz süresidir. Fakat bu yüksek RAM ihtiyacını ortadan kaldırmaz. Çünkü çok sayıda parmak izi ve herbirinin benzerlik eşleştirmesi yüksek hafıza gerektirir. Bu çalışmada standart bir dizüstü bilgisayar ile kullanılan 7 bileşen 2 gün süreli veri için en uzun çalışma zamanı parmak izi üretme aşamasında ortaya çıkmış ve yaklaşık 1 dakika 35 sn sürmüştür. Bu süreler diğer eşleştirme yöntemlerine göre çok daha kısadır (Yoon ve diğ., 2005).Akma (krip) gösteren fayların en belirgin özelliklerinden biri tekrarlayan (repeating) depremler üretmesidir. Bu depremler benzer kaynak ve benzer seyahat yolları nedeniyle istasyonlarda çok benzer kayıt formları oluştururlar. Bu nedenle FAST tekrarlayan depremlerin keşfi için oldukça iyi bir yöntem olabilir.

Gelecek çalışmalarda, FAST'in algılama yeteneği düşük S/N, örtüşen dalga formları, ilişkili gürültü veya impulsive olmayan varışlı dalga formları gibi algılama için zorluklar yaratan veri setlerinde test edilebilir. Ayrıca daha ayırt edici parmak izleri geliştirmek ve veri tabanına bu parmak izlerini eklemenin farklı yolları bulunabilir. FAST verilen bir sorgu olayına (query event) benzer olayları neredeyse sabit bir zamanda tespit edebilmektir. Bu nedenle bu teknik gerçek zamanlı deprem izleme için de uygulanabilir. Ancak FAST önceden bilgilendirilen bir dedektör olmaması nedeniyle şablon eşleştirme gibi dedektörlere göre daha fazla yanlış algılama oranına sahip olması da gerçek zamanlı deprem izlemeye dahil edilmek istenen FAST algoritması için önemli bir noktadır. Ayrıca FAST'in LSH tabanlı bir benzerlik arama yapması yoğun bellek kullanımını gerektirmektedir. Bu durum yüzlerce sismik istasyondan gelen sismik veriler göz önüne alındığında gerçek zamanlı deprem izleme için bir sorun teşkil edebilir. FAST tarafından oluşturulacak bir parmak izi veri tabanı ile veri tabanına eklenecek diğer parmak izleri arasındaki benzerliklere bakılarak doğru ve yanlış algılamalar sınıflandırılabilinir. Böylece oluşturulan parmak izi veri tabanındaki parmak izleri şablon eşleştirmede olduğu gibi bir şablon parmak izi görevinde kullanılarak bu veri tabanına karşı sorgulanabilir. Böylelikle STA/LTA tarafından kaçırılan benzer depremleri ya da çeşitli deprem dizilerinin (ön şok, artçı şok, deprem sürüleri, tetiklenen depremler, LFE, indüklenen depremsellik, volkanik aktivite) eşleşen şablon dalga formları da bulunabilir. Hassasiyetin

artırılarak büyük ölçekli sismik bir ağ boyunca yapılacak bir algılama ile kataloglarda tanımlanamayan büyüklükler tespit edilebilir.

KAYNAKLAR

Aguiar, A. C., & Beroza, G. C. (2014). PageRank for earthquakes. *Seismological Research Letters*, *85*(2), 344-350.

Akaike, H. (1971). Autoregressive model fitting for control. Ann. Inst. Statist. Math., 23, 163-180.

Aksoy, M.E., 2021. The 9 August 1912 MürefteŞarköy earthquake of the North Anatolian fault. Med. Geosc. Rev., 3, 95–114. https://doi.org/10.1007/s42990-021-00050-z

Allen, R. V. (1978). Automatic earthquake recognition and timing from single traces. Bull. Seism. Soc. Am., 68, 1521-1532.

Allen, R. V. (1982). Automatic phase pickers: Their present and future prospects. Bull. Seism. Soc. Am., 72, 225-242.

Altunel, E., Meghraoui, M., Akyüz, H.S., Dikbaş, A. 2004. Characteristics of the 1912 co-seismic rupture along the North Anatolian fault zone (Turkey): implications for the expected Marmara earthquake. Terra Nova 16, 198–204. https://doi.org/10.1111/j.1365-3121.2004.00552.x

Andoni, A., & Indyk, P. (2008). Near-optimal hashing algorithms for approximate nearest neighbor in high dimensions. *Communications of the ACM*, *51*(1), 117-122.

Antonini, M., Barlaud, M., Mathieu, P., & Daubechies, I. (1992). Image coding using wavelet transform. *IEEE Transactions on image processing*, *1*(2), 205-220.

Armijo, R. vd. 2005. Submarine fault scarps in the Sea of Marmara pull-apart (North Anatolian Fault): Implications for seismic hazard in Istanbul. Geochem Geophys Geosystems 6, Q06009. https://doi.org/10.1029/2004G C000896

Audretsch, J. (2020), *Earthquake Detection using Deep Learning Based Approaches* Thesis (PhD), King Abdullah University of Science and Technology.

Baer, M., & Kradolfer, U. (1987). An automatic phase picker for local and teleseismic events. *Bulletin of the Seismological Society of America*, *77*(4), 1437-1445.

Baluja, S., & Covell, M. (2008). Waveprint: Efficient wavelet-based audio fingerprinting. *Pattern recognition*, *41*(11), 3467-3480.

Bardainne, T., Gaillot, P., Dubos-Sallée, N., Blanco, J., & Sénéchal, G. (2006). Characterization of seismic waveforms and classification of seismic events using chirplet atomic decomposition. Example from the Lacq gas field (Western Pyrenees, France). *Geophysical Journal International*, *166*(2), 699-718.

Bentley, J. L. (1975). Multidimensional binary search trees used for associative searching. *Communications of the ACM*, *18*(9), 509-51

Bergen, K. J., & Beroza, G. C. (2018). Detecting earthquakes over a seismic network using single-station similarity measures. Geophysical Journal International, 213(3), 1984-1998.

Bergen, K. J. (2018). *Big Data for Small Earthquakes: Detecting Earthquakes over a Seismic Network with Waveform Similarity Search*. Stanford University.

Beyreuther, M., Carniel, R., & Wassermann, J. (2008). Continuous Hidden Markov Models: Application to automatic earthquake detection and classification at Las Canãdas caldera, Tenerife. *Journal of Volcanology and Geothermal Research*, *176*(4), 513-518.

Beyreuther, M., & Wassermann, J. (2008). Continuous earthquake detection and classification using discrete Hidden Markov Models. *Geophysical Journal International*, *175*(3), 1055-1066.

Broder, A. Z. (1993). Some applications of Rabin's fingerprinting method. In *Sequences II* (pp. 143-152). Springer, New York, NY.

Broder, A. Z., Glassman, S. C., Manasse, M. S., & Zweig, G. (1997). Syntactic clustering of the web. *Computer networks and ISDN systems*, *29*(8-13), 1157-1166.

Broder, A. Z. (2000, June). Identifying and filtering near-duplicate documents. In *Annual symposium on combinatorial pattern matching* (pp. 1-10). Springer, Berlin, Heidelberg.

Brown, J. R., Beroza, G. C., & Shelly, D. R. (2008). An autocorrelation method to detect low frequency earthquakes within tremor. *Geophysical Research Letters*, *35*(16).

Cano, P., Batlle, E., Kalker, T., & Haitsma, J. (2005b). A review of audio fingerprinting. Journal of VLSI Signal Processing Systems for Signal, Image, and Video Technology, 41(3 SPEC. ISS.):271–284.

Dai, H., & MacBeth, C. (1995). Automatic picking of seismic arrivals in local earthquake data using an artificial neural network. *Geophysical journal international*, *120*(3), 758-774.

Dai, H., & MacBeth, C. (1997). The application of back-propagation neural network to automatic picking seismic arrivals from single-component recordings. *Journal of Geophysical Research: Solid Earth*, *102*(B7), 15105-15113.

Del Pezzo, E., Esposito, A., Giudicepietro, F., Marinaro, M., Martini, M., & Scarpetta, S. (2003). Discrimination of earthquakes and underwater explosions using neural networks. *Bulletin of the Seismological Society of America*, *93*(1), 215-223.

Donoho, D. L., & Johnstone, I. M. (1994, November). Threshold selection for wavelet shrinkage of noisy data. In *Proceedings of 16th annual international conference of the IEEE engineering in medicine and biology society* (Vol. 1, pp. A24-A25). IEEE.

Draelos, T. J., Peterson, M. G., Knox, H. A., Lawry, B. J., Phillips-Alonge, K. E., Ziegler, A. E., ... & Faust, A. (2018). Dynamic Tuning of Seismic Signal Detector Trigger Levels for Local NetworksDynamic Tuning of Seismic Signal Detector Trigger Levels for Local Networks. *Bulletin of the Seismological Society of America*, *108*(3A), 1346-1354.

Dysart, P. S., & Pulli, J. J. (1990). Regional seismic event classification at the NORESS array: seismological measurements and the use of trained neural networks. *Bulletin of the Seismological Society of America*, *80*(6B), 1910-1933.

Esposito, A. M., Giudicepietro, F., Scarpetta, S., D'auria, L., Marinaro, M., & Martini, M. (2006). Automatic discrimination among landslide, explosion-quake, and microtremor seismic signals at Stromboli volcano using neural networks. *Bulletin of the Seismological Society of America*, *96*(4A), 1230-1240.

Freiberger, W. F. (1963). An approximation method in signal detection. Quart. J. App. Math. 20, 373-378.

Gentili, S., & Michelini, A. (2006). Automatic picking of P and S phases using a neural tree. *Journal of Seismology*, *10*(1), 39-63.

Goforth, T., & Herrin, E. (1981). An automatic seismic signal detection algorithm based on the Walsh transform. *Bulletin of the Seismological Society of America*, *71*(4), 1351-1360.

Hampel, F. R. (1974). The influence curve and its role in robust estimation. *Journal of the american statistical association*, *69*(346), 383-393.

Haykin, S., & Principe, J. (1998). Making sense of a complex world [chaotic events modeling]. *IEEE Signal Processing Magazine*, *15*(3), 66-81.

Heintze, N. (1996, November). Scalable document fingerprinting. In *1996 USENIX workshop on electronic commerce* (Vol. 3, No. 1).

Jansen, A., & Van Durme, B. (2011, December). Efficient spoken term discovery using randomized algorithms. In *2011 IEEE Workshop on Automatic Speech Recognition & Understanding* (pp. 401-406). IEEE.

Johnson, C. E., Lindh, A., & Hirshorn, B. (1997). Robust regional phase association.

Joswig, M. (1987). Methoden zur automatischen Erfassung und Auswertung von Erdbeben in seismischen Netzen und ihre Realisierung beim Aufbau des lokalen 'Bochum University Germany'-Netzes. Berichte des Instituts für Geophysik der Ruhr-Universität Bochum, Reihe A, No. 23.

Joswig, M. (1990). Pattern recognition for earthquake detection. *Bulletin of the Seismological Society of America*, *80*(1), 170-186.Kohonen, T. (2013). Essentials of the self-organizing map. Neural networks, 37, 52-65.

Küperkoch, L., Meier, T., Lee, J., Friederich, W. and Working Group, E. (2010), Automated determination of *P*-phase arrival times at regional and local distances using higher order statistics. Geophysical Journal International, 181: 1159-1170. https://doi.org/10.1111/j.1365-246X.2010.04570.x

Küperkoch, L., Meier, T., & Diehl, T. (2011). Chapter 16: Automated Event and Phase Identification. IASPEI New Manual of Seismological Observatory Practice (NMSOP).

Küperkoch, L., Meier, T., & Diehl, T. (2012). Automated event and phase identification. In *New Manual of Seismological Observatory Practice 2 (NMSOP-2)* (pp. 1-52). Deutsches GeoForschungsZentrum GFZ.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, *521*(7553), 436-444.

Leonard, M., & Kennett, B. L. N. (1999). Multi-component autoregressive techniques for the analysis of seismograms. *Physics of the Earth and Planetary Interiors*, *113*(1-4), 247-263.

Levitin, A. (2015). "Introduction to the Design and Analysis of Algorithms", Pearson Education, 2012.

Manber, U. (1994, January). Finding Similar Files in a Large File System. In *Usenix winter* (Vol. 94, pp. 1-10).

Masiello, S., Esposito, A. M., Scarpetta, S., Giudicepietro, F., Esposito, A., & Marinaro, M. (2006). Application of self organized maps and curvilinear component analysis to the discrimination of the Vesuvius seismic signals. In *WSOM*.

Michael, A. J., Gildea, S. P., & Pulli, J. J. (1982). A real-time digital seismic event detection and recording system for network applications. *Bulletin of the Seismological Society of America*, *72*(6A), 2339-2348.

Mykkeltveit, S., & Bungum, H. (1984). Processing of regional seismic events using data from small-aperture arrays. *Bulletin of the Seismological Society of America*, *74*(6), 2313-2333.

Ohrnberger, M. (2001). *Continuous automatic classification of seismic signals of volcanic origin at Mt. Merapi, Java, Indonesia* (Doctoral dissertation, Potsdam, Univ., Diss., 2001).

Peng, Z. and Zhao, P. (2009). Migration of early aftershocks following the 2004 Parkfield earthquake. Nature Geoscience, 2(12):877–881.

Perol, T., Gharbi, M., & Denolle, M. (2018). Convolutional neural network for earthquake detection and location. *Science Advances*, *4*(2), e1700578.

Rabiner, L. R. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, *77*(2), 257-286.

Reynen, A., & Audet, P. (2017). Supervised machine learning on a network scale: Application to seismic event classification and detection. *Geophysical Journal International*, *210*(3), 1394-1409.

Riggelsen, C., Ohrnberger, M., & Scherbaum, F. (2007, September). Dynamic Bayesian networks for real-time classification of seismic signals. In *European Conference on Principles of Data Mining and Knowledge Discovery* (pp. 565-572). Springer, Berlin, Heidelberg.

Riggelsen, C., & Ohrnberger, M. (2014). A machine learning approach for improving the detection capabilities at 3C seismic stations. *Pure and Applied Geophysics*, *171*(3), 395-411.

Ringdal, F., & Kværna, T. (1989). A multi-channel processing approach to real time network detection, phase association, and threshold monitoring. *Bulletin of the Seismological Society of America*, *79*(6), 1927-1940.

Rockwell, T.K., Barka, A., Dawson, T., Akyüz, S., Thorup, K. 2001. Paleoseismology of the Gazikoy-Saros segment of the North Anatolia fault, northwestern Turkey: comparison of the historical and paleoseismic records, implications of regional seismic hazard, and models of earthquake recurrence. J. Seismol. 5, 433–448. https://doi.org/10.1023/A:10114 35927983.

Ross, Z. E., Meier, M. A., Hauksson, E., & Heaton, T. H. (2018). Generalized seismic phase detection with deep learningshort note. *Bulletin of the Seismological Society of America*, *108*(5A), 2894-2901.

Saragiotis, C. D., Hadjileontiadis, L. J., & Panas, S. M. (2002). PAI-S/K: A robust automatic seismic P phase arrival identification scheme. *IEEE Transactions on Geoscience and Remote Sensing*, *40*(6), 1395-1404.

Scarpetta, S., Giudicepietro, F., Ezin, E. C., Petrosino, S., Del Pezzo, E., Martini, M., & Marinaro, M. (2005). Automatic classification of seismic signals at Mt. Vesuvius volcano, Italy, using neural networks. *Bulletin of the Seismological Society of America*, *95*(1), 185-196.

Sereno Jr, T. J., & Patnaik, G. B. (1993). *Initial wave-type identification with neural networks and its contribution to automated processing in IMS version 3.0*. SCIENCE APPLICATIONS INTERNATIONAL CORP SAN DIEGO CA.

Skoumal, R. J., Brudzinski, M. R., & Currie, B. S. (2016). An efficient repeating signal detector to investigate earthquake swarms. *Journal of Geophysical Research: Solid Earth*, *121*(8), 5880-5897.

Slinkard, M. E., Carr, D. B., & Young, C. J. (2013). Applying waveform correlation to three aftershock sequences. *Bulletin of the Seismological Society of America*, *103*(2A), 675-693.

Stewart, S. W. (1977). Real-time detection and location of local seismic events in Central California. Bull. Seism. Soc. Am., 67, 2, 433-452

Stollnitz, E. J., DeRose, A. D., & Salesin, D. H. (1995). Wavelets for computer graphics: a primer. 1. *IEEE computer graphics and applications*, *15*(3), 76-84.

Takanami, T., and Kitagawa, G. (1988). A new efficient procedure for estimation of onset times of seismic waves. J. Phys. Earth, 36, 267-290.

Tiira, T. (1999). Detecting teleseismic events using artificial neural networks. *Computers & Geosciences*, *25*(8), 929-938.

Trnkoczy, A. (2009). Understanding and parameter setting of STA/LTA trigger algorithm. In New Manual of Seismological Observatory Practice (NMSOP) (pp. 1-20). Deutsches GeoForschungsZentrum GFZ.

Uçarkuş, G., Çakır, Z., Armijo, R. 2011. Western termination of the Mw 7.4, 1999 İzmit earthquake rupture: Implications for the expected large earthquake in the Sea of Marmara. Turkish J. Earth Sci. 20, 379–394.

Valentine, A. P., & Trampert, J. (2012). Data space reduction, quality assessment and searching of seismograms: autoencoder networks for waveform data. *Geophysical Journal International*, *189*(2), 1183-1202.

Wang, J., & Teng, T. L. (1997). Identification and picking of S phase using an artificial neural network. *Bulletin of the Seismological Society of America*, *87*(5), 1140-1149.

Wu, H., Chen, Z., Sun, W., Zheng, B., & Wang, W. (2017). Modeling trajectories with recurrent neural networks. IJCAI.

Wu, Y., Lin, Y., & Zhou, Z. (2018, October). InversionNet: Accurate and efficient seismic waveform inversion with convolutional neural networks. In *2018 SEG International Exposition and Annual Meeting*. OnePetro.

Wiszniowski, J., Plesiewicz, B. M., & Trojanowski, J. (2014). Application of real time recurrent neural network for detection of small natural earthquakes in Poland. *Acta Geophysica*, *62*(3), 469-485.

Yalçınkaya, E., Bohnhoff, M., Görgün, E., Hakan, A. L. P., Bentz, S., Pınar, A., ... & Görgün, B. Ganos fayı güncel deprem etkinliğinin değerlendirilmesi: MONGAN sismik ağ yapısı ve veri kalitesi. *Yerbilimleri*, *43*(1), 37-60.

Yoon, C.E., O'Reilly, O., Bergen, K.J. & Beroza, G.C., 2015. Earthquake detection through computationally efficient similarity search, Sci. Adv., 1(11), e1501057, doi:10.1126/sciadv.1501057.

Yoon, C. E. (2018). *A fast data mining approach for similar earthquake detection*. Stanford University.

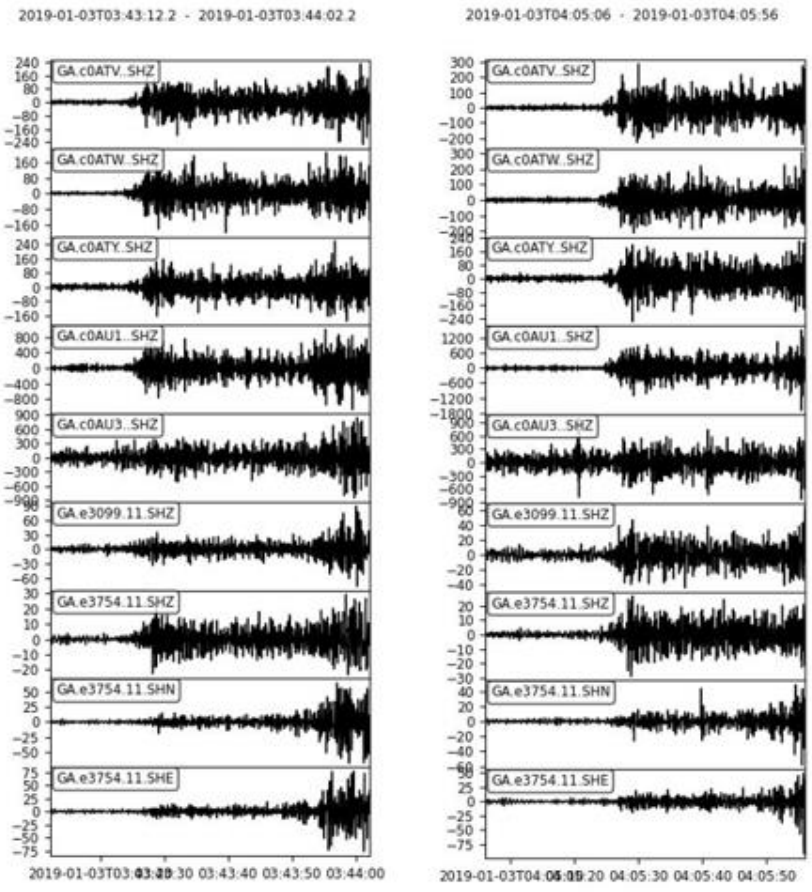
Zhao, Y., & Takano, K. (1999). An artificial neural network approach for broadband seismic phase picking. *Bulletin of the Seismological Society of America*, *89*(3), 670-680.

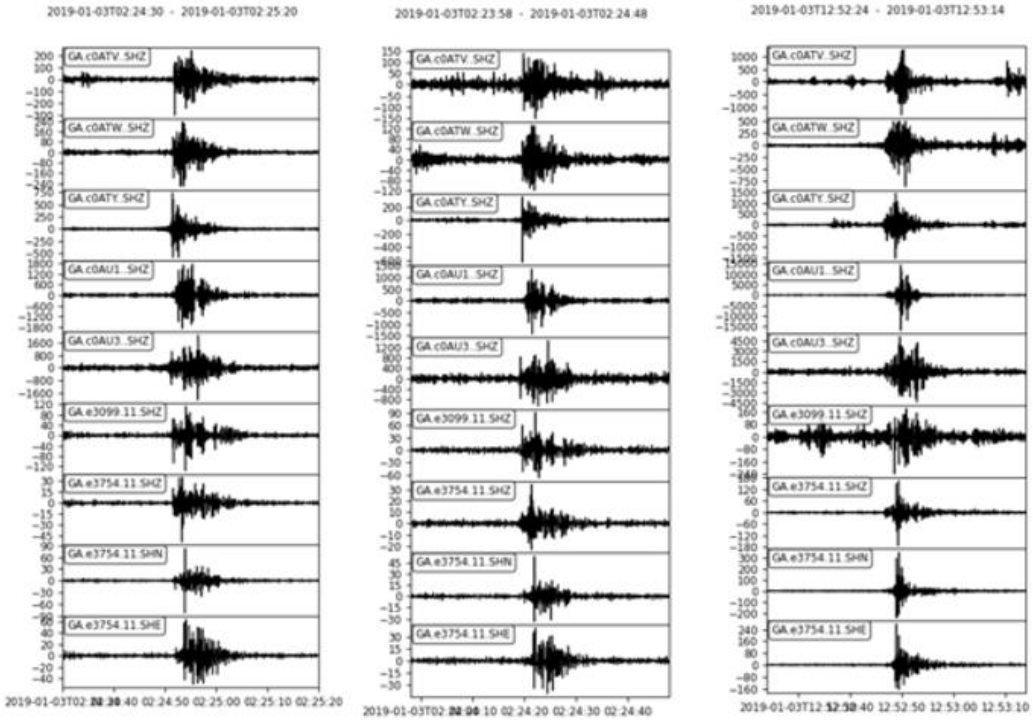
Zhang, M. and Wen, L. (2015). An effective method for small event detection: Match and Locate (M&L). Geophysical Journal International, 200(3):1523–1537.

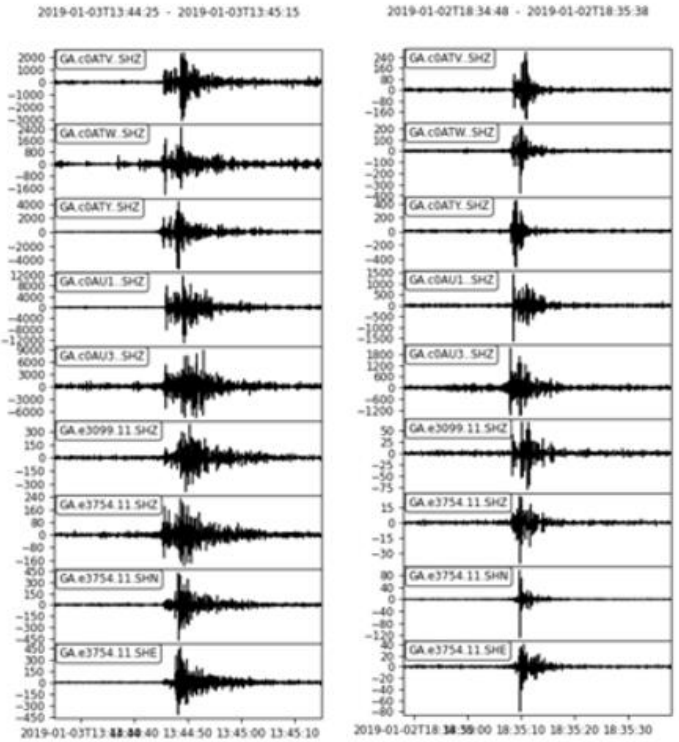
Zhu, W., Mousavi, S. M., & Beroza, G. C. (2019). Seismic signal denoising and decomposition using deep neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, *57*(11), 9476-9488. Zhang, M. and Wen, L. (2015). An effective method for small event detection: Match and Locate (M&L). Geophysical Journal International, 200(3):1523–1537.

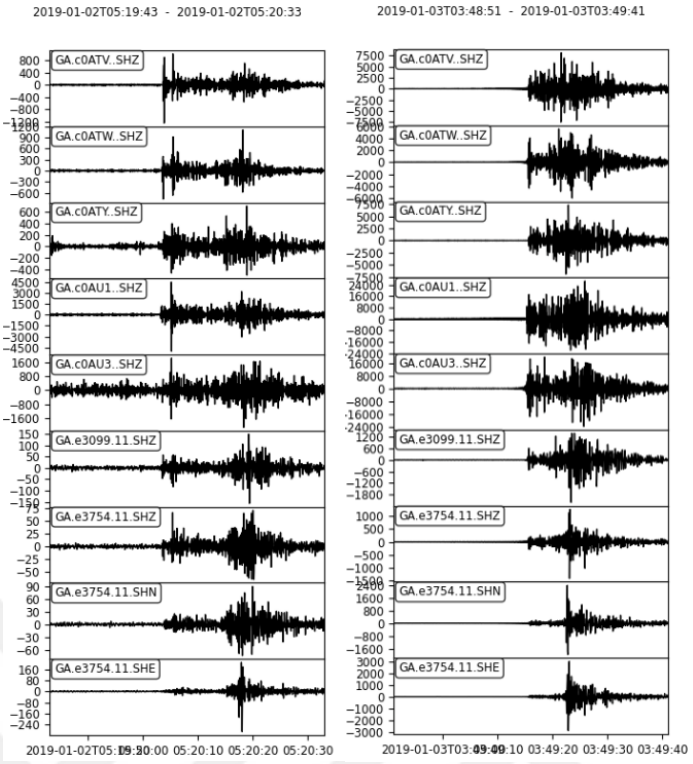
EKLER

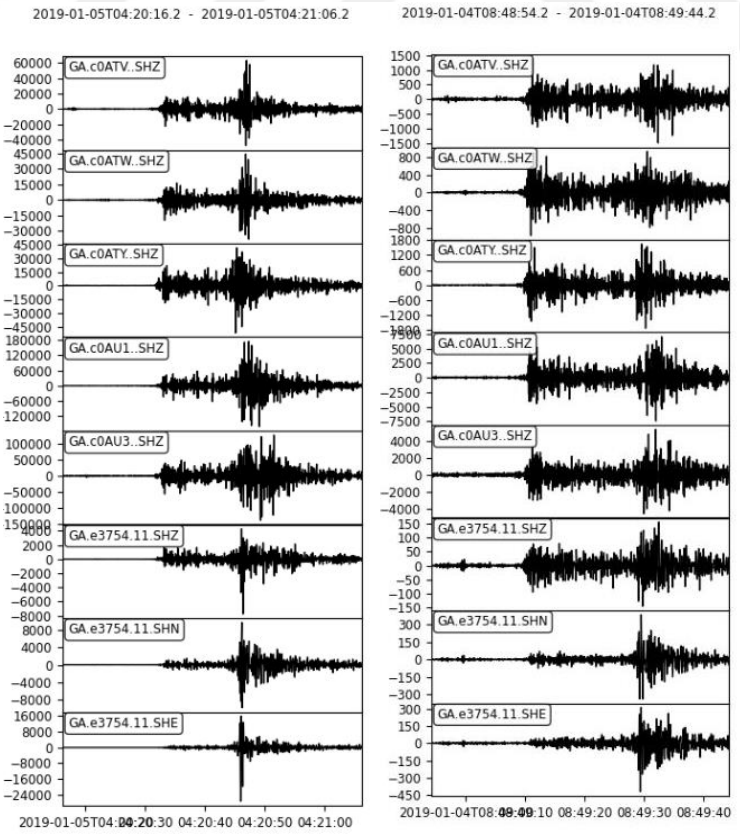
EK 1. *r*=4 *v*=2 parametre kombinasyonu tarafından algılanan 114 deprem yer almaktadır. Şekillerde istasyonlar tarafından kaydedilen depremler 50 sn'lik pencereler ile gösterilmiştir. Şekillerin en üstlerinde depremlerin başlangıç ve bitiş zamanları yer almaktadır. Sol üst köşelerde istasyon ve bileşen adları yer almaktadır. Depremler dalga formu benzerliklerine göre gruplandırılmıştır.

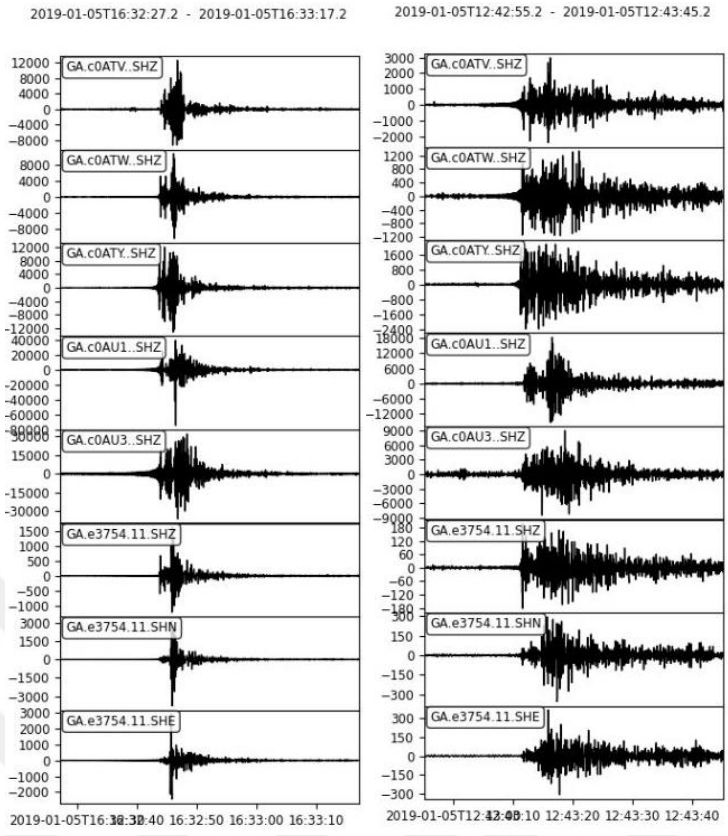


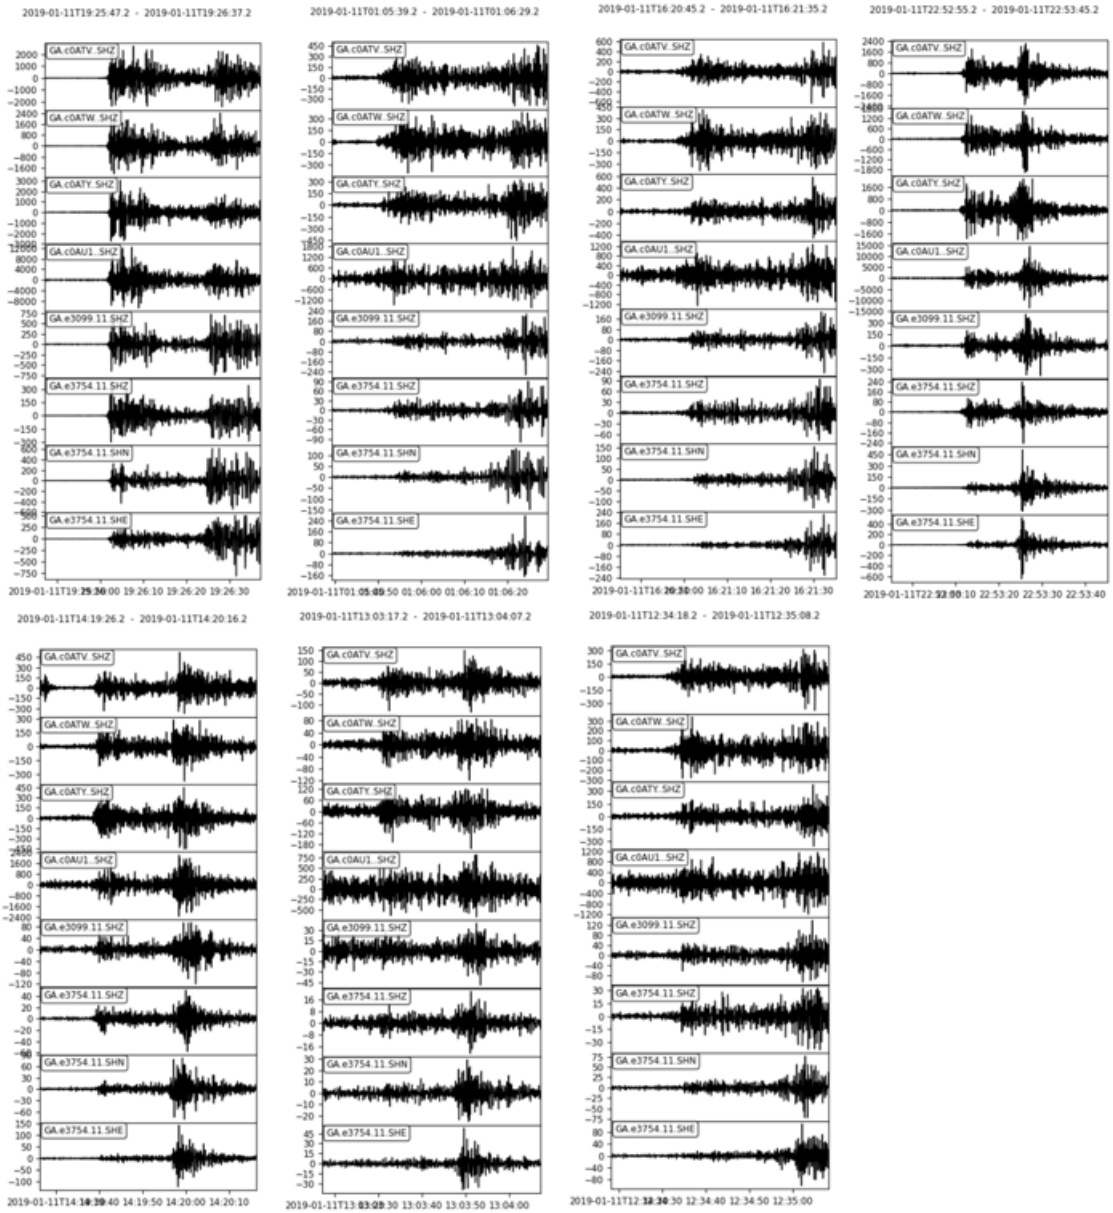

2019-01-03T02:24:30 - 2019-01-03T02:25:20
2019-01-03T02:23:58 - 2019-01-03T02:24:48
2019-01-03T12:52:24 - 2019-01-03T12:53:14
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

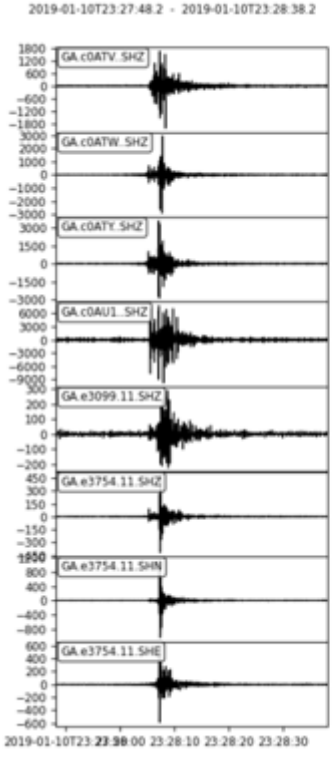

2019-01-03T13:44:25 - 2019-01-03T13:45:15
2019-01-02T18:34:48 - 2019-01-02T18:35:38
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

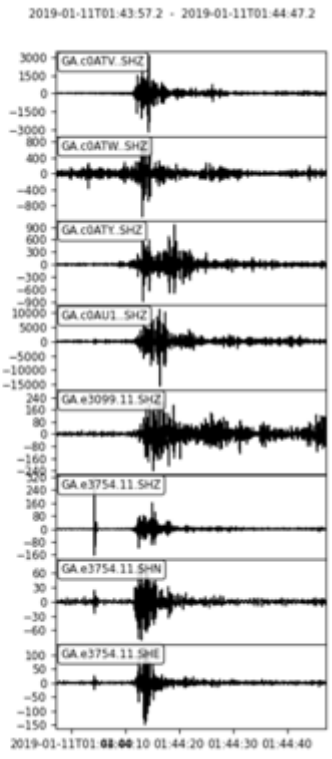

2019-01-02T05:19:43 - 2019-01-02T05:20:33
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-02T05:19:50 05:20:00 05:20:10 05:20:20 05:20:30
2019-01-03T03:48:51 - 2019-01-03T03:49:41
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-03T03:49:00 03:49:10 03:49:20 03:49:30 03:49:40

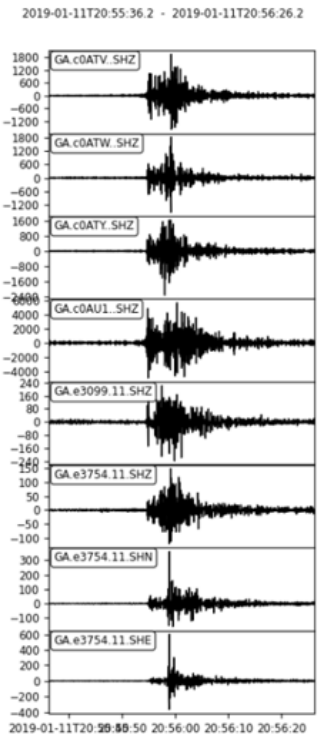

2019-01-05T04:20:16.2 - 2019-01-05T04:21:06.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-05T04:20:20 04:20:30 04:20:40 04:20:50 04:21:00
2019-01-04T08:48:54.2 - 2019-01-04T08:49:44.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-04T08:49:00 08:49:10 08:49:20 08:49:30 08:49:40

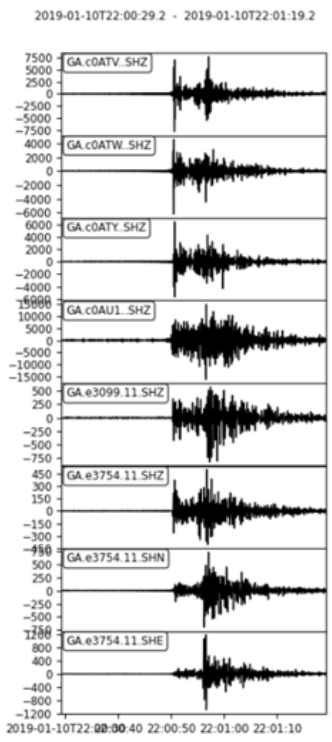

2019-01-05T16:32:27.2 - 2019-01-05T16:33:17.2
2019-01-05T12:42:55.2 - 2019-01-05T12:43:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-05T16:32:40 16:32:50 16:33:00 16:33:10
2019-01-05T12:43:10 12:43:20 12:43:30 12:43:40

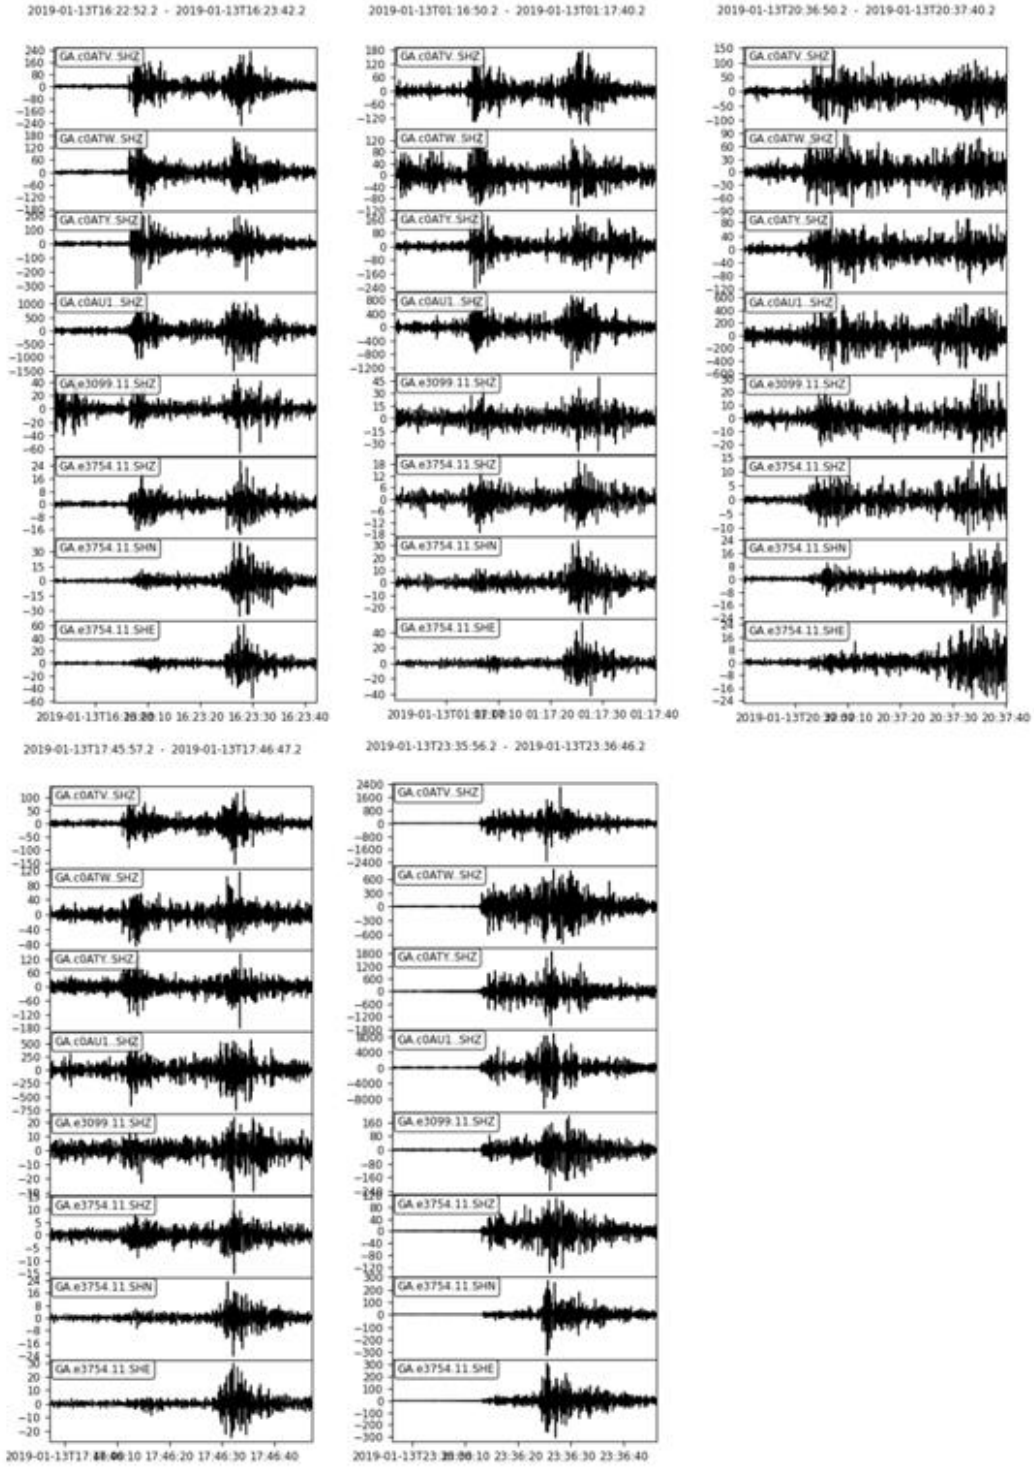

2019-01-11T19:25:47.2 - 2019-01-11T19:26:37.2
2019-01-11T01:05:39.2 - 2019-01-11T01:06:29.2
2019-01-11T16:20:45.2 - 2019-01-11T16:21:35.2
2019-01-11T22:52:55.2 - 2019-01-11T22:53:45.2
2019-01-11T14:19:26.2 - 2019-01-11T14:20:16.2
2019-01-11T13:03:17.2 - 2019-01-11T13:04:07.2
2019-01-11T12:34:18.2 - 2019-01-11T12:35:08.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

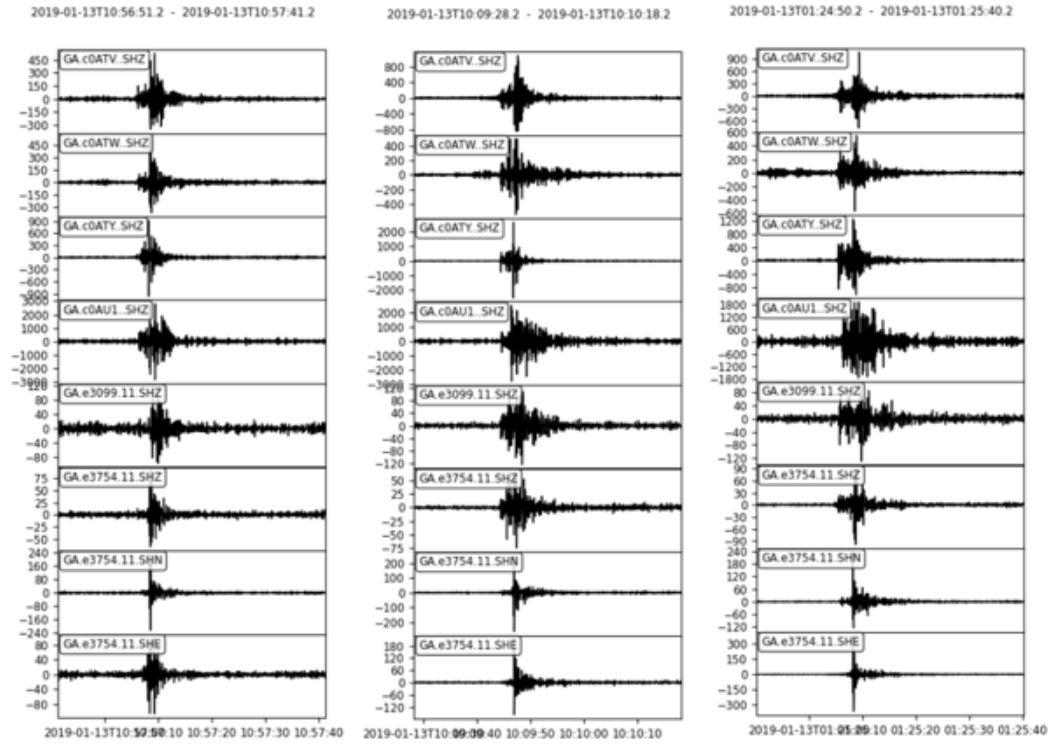

2019-01-10T23:27:48.2 - 2019-01-10T23:28:38.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-10T23:28:00 23:28:10 23:28:20 23:28:30

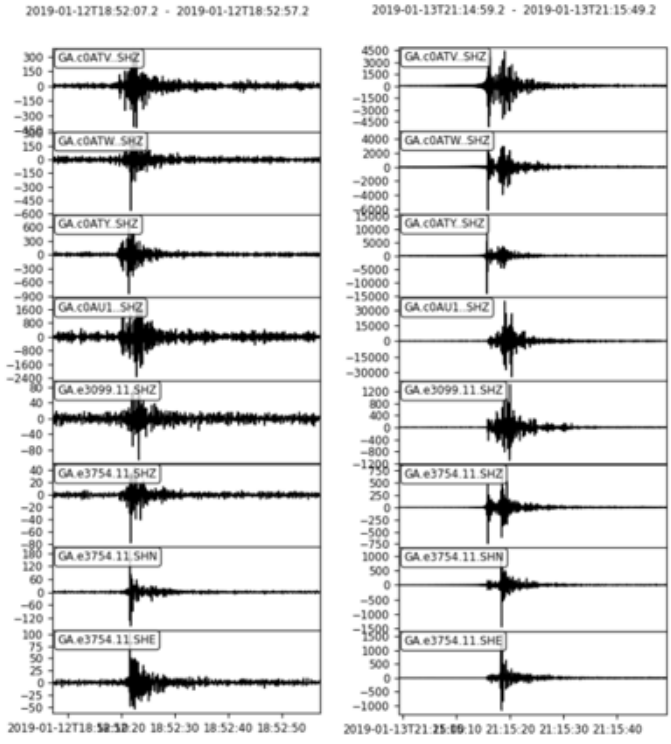

2019-01-11T01:43:57.2 - 2019-01-11T01:44:47.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
01:44:10 01:44:20 01:44:30 01:44:40

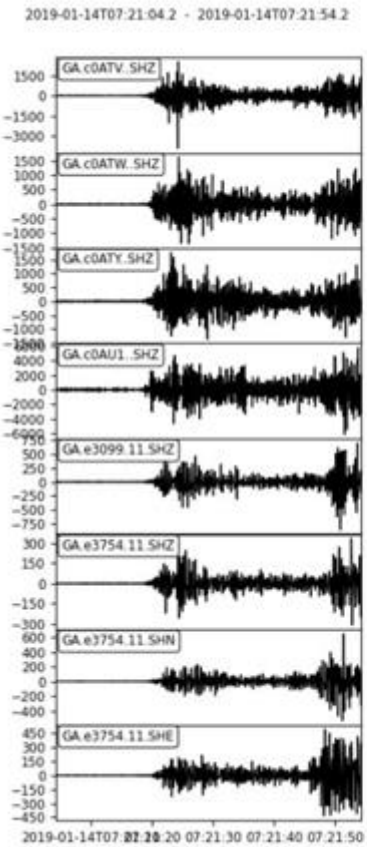

2019-01-11T20:55:36.2 - 2019-01-11T20:56:26.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
20:56:00 20:56:10 20:56:20

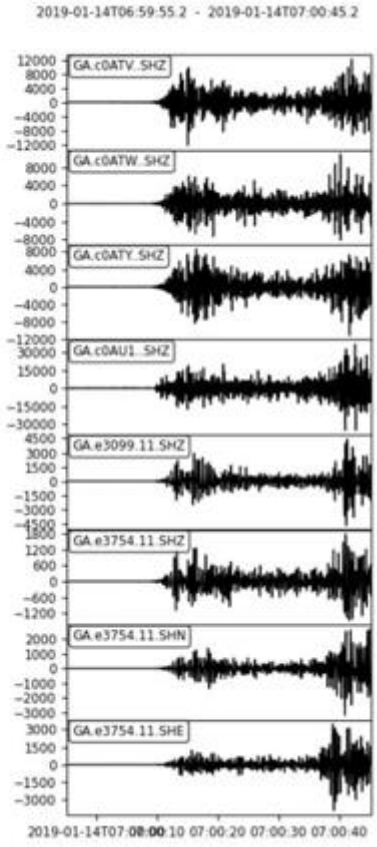

2019-01-10T22:00:29.2 - 2019-01-10T22:01:19.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
22:00:40 22:00:50 22:01:00 22:01:10

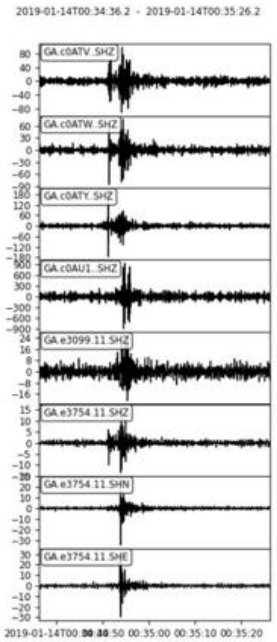

2019-01-13T16:22:52.2 - 2019-01-13T16:23:42.2
2019-01-13T01:16:50.2 - 2019-01-13T01:17:40.2
2019-01-13T20:36:50.2 - 2019-01-13T20:37:40.2
2019-01-13T17:45:57.2 - 2019-01-13T17:46:47.2
2019-01-13T23:35:56.2 - 2019-01-13T23:36:46.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

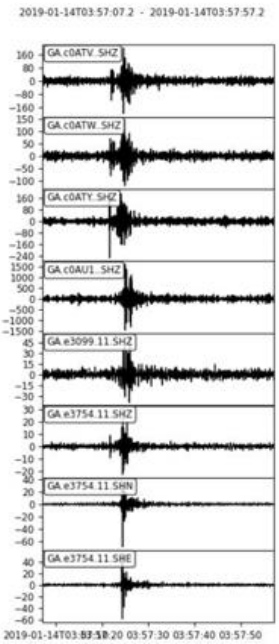

2019-01-13T10:56:51.2 - 2019-01-13T10:57:41.2
2019-01-13T10:09:28.2 - 2019-01-13T10:10:18.2
2019-01-13T01:24:50.2 - 2019-01-13T01:25:40.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-13T10:57:00 10:57:10 10:57:20 10:57:30 10:57:40
2019-01-13T10:09:40 10:09:50 10:10:00 10:10:10
2019-01-13T01:25:00 01:25:10 01:25:20 01:25:30 01:25:40

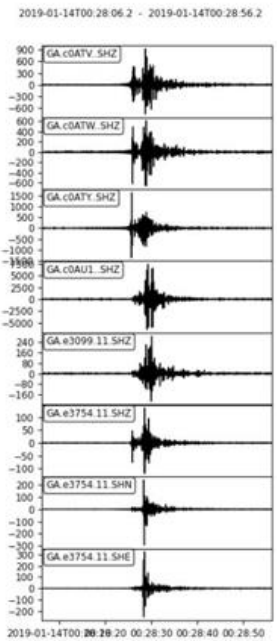

2019-01-12T18:52:07.2 - 2019-01-12T18:52:57.2
2019-01-13T21:14:59.2 - 2019-01-13T21:15:49.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-12T18:52:00 18:52:10 18:52:20 18:52:30 18:52:40 18:52:50
2019-01-13T21:15:00 21:15:10 21:15:20 21:15:30 21:15:40

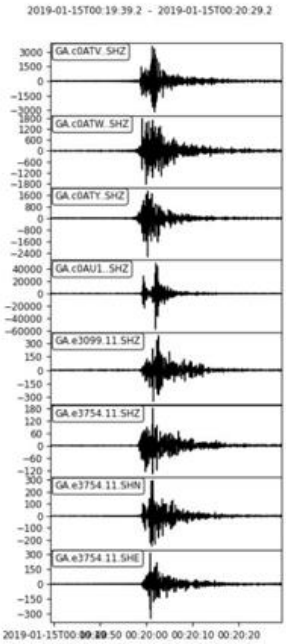

2019-01-14T07:21:04.2 - 2019-01-14T07:21:54.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-14T07:21:20 07:21:30 07:21:40 07:21:50

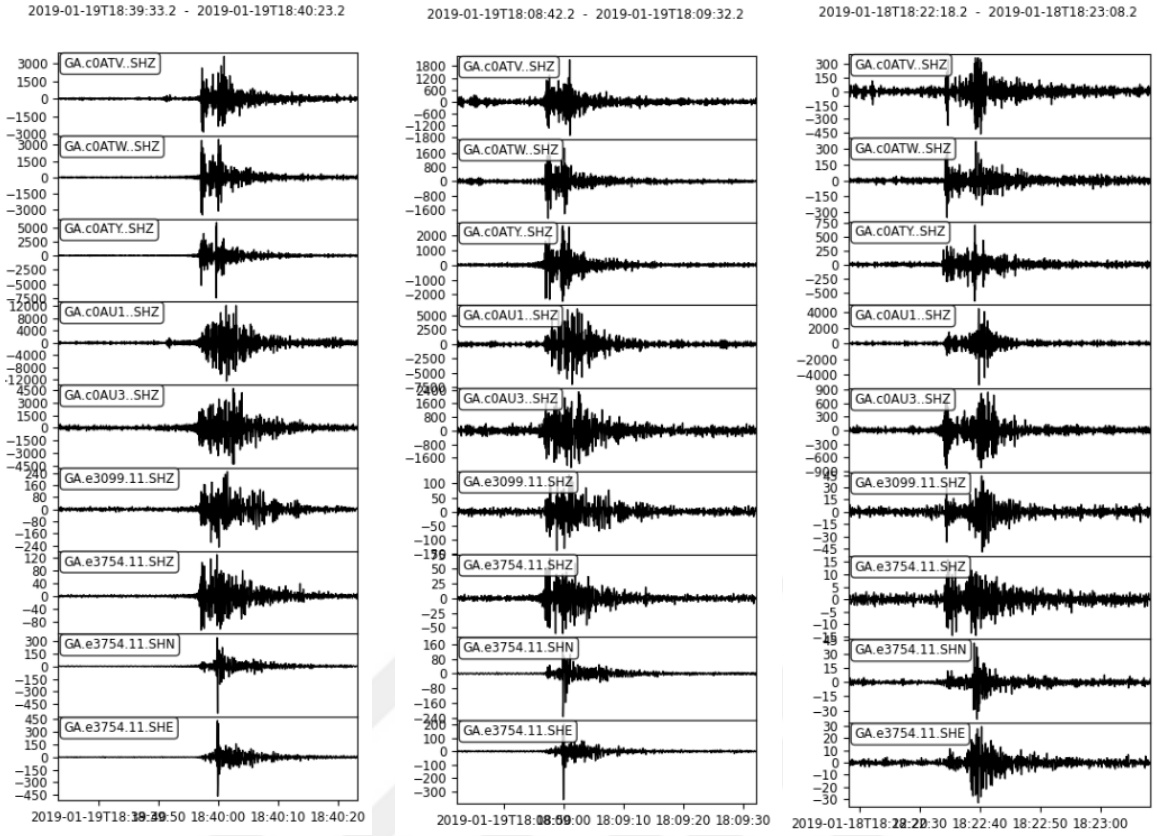

2019-01-14T06:59:55.2 - 2019-01-14T07:00:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-14T07:00:10 07:00:20 07:00:30 07:00:40

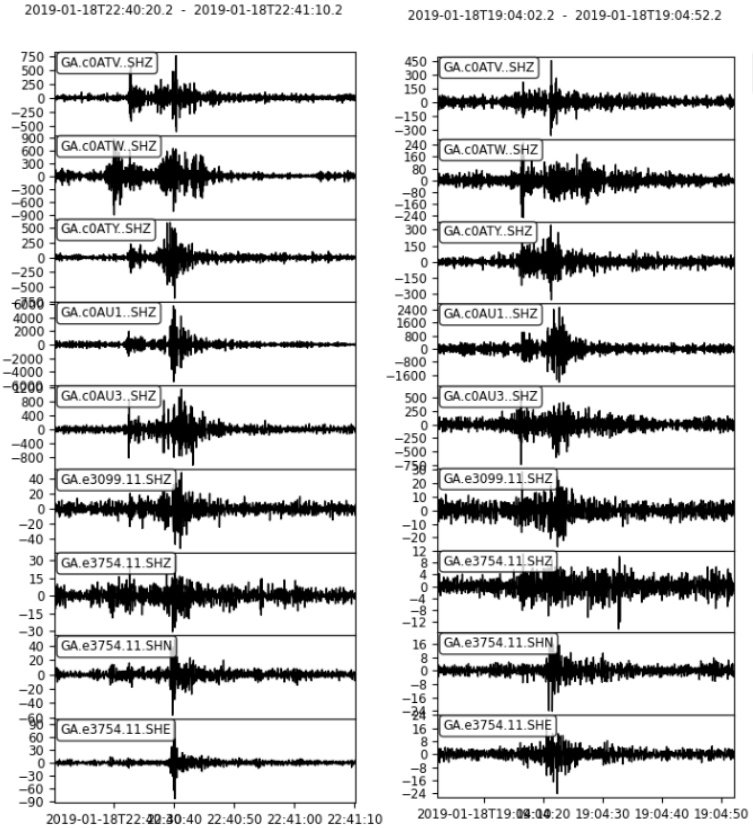

2019-01-14T00:34:36.2 - 2019-01-14T00:35:26.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-14T00:35:00 00:35:10 00:35:20

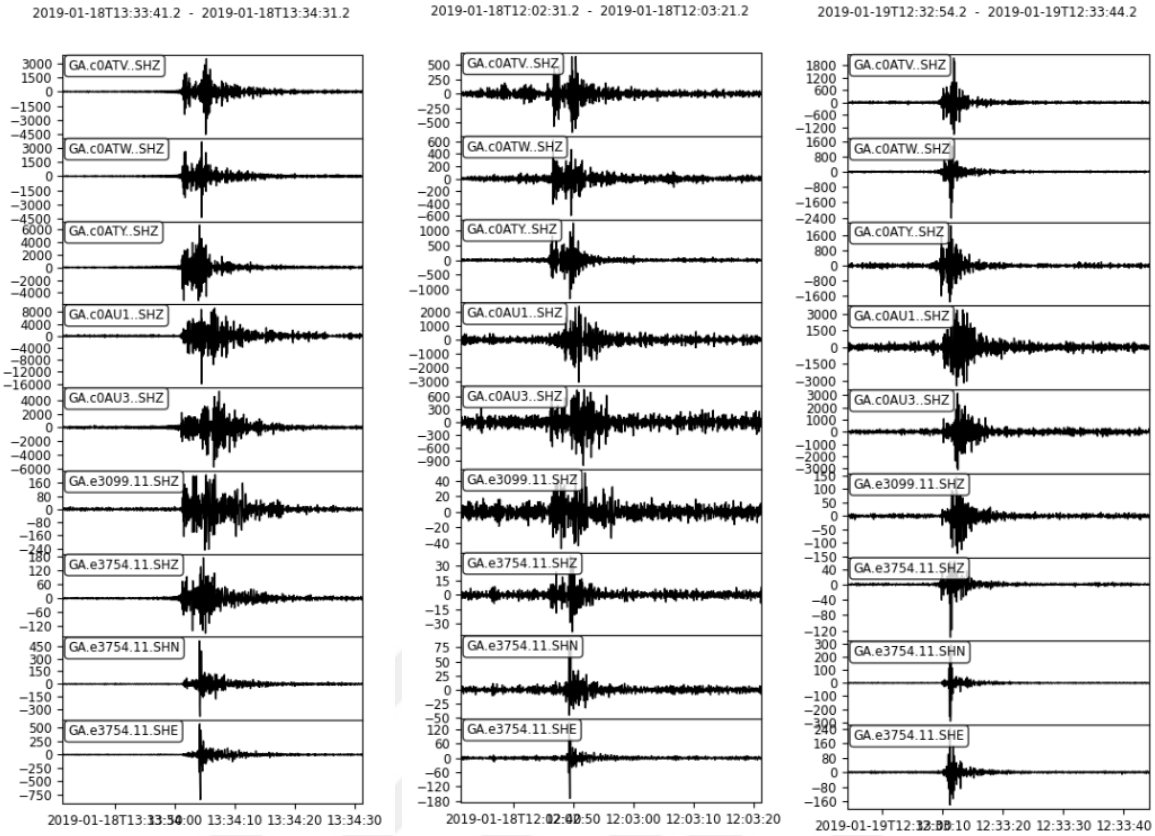

2019-01-14T03:57:07.2 - 2019-01-14T03:57:57.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-14T03:57:20 03:57:30 03:57:40 03:57:50

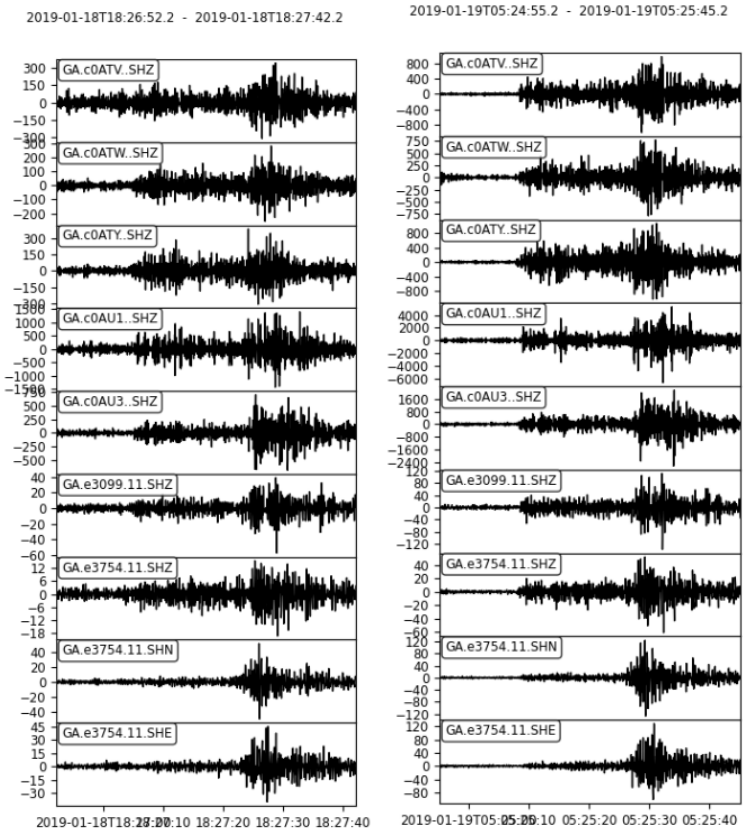

2019-01-14T00:28:06.2 - 2019-01-14T00:28:56.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-14T00:28:20 00:28:30 00:28:40 00:28:50

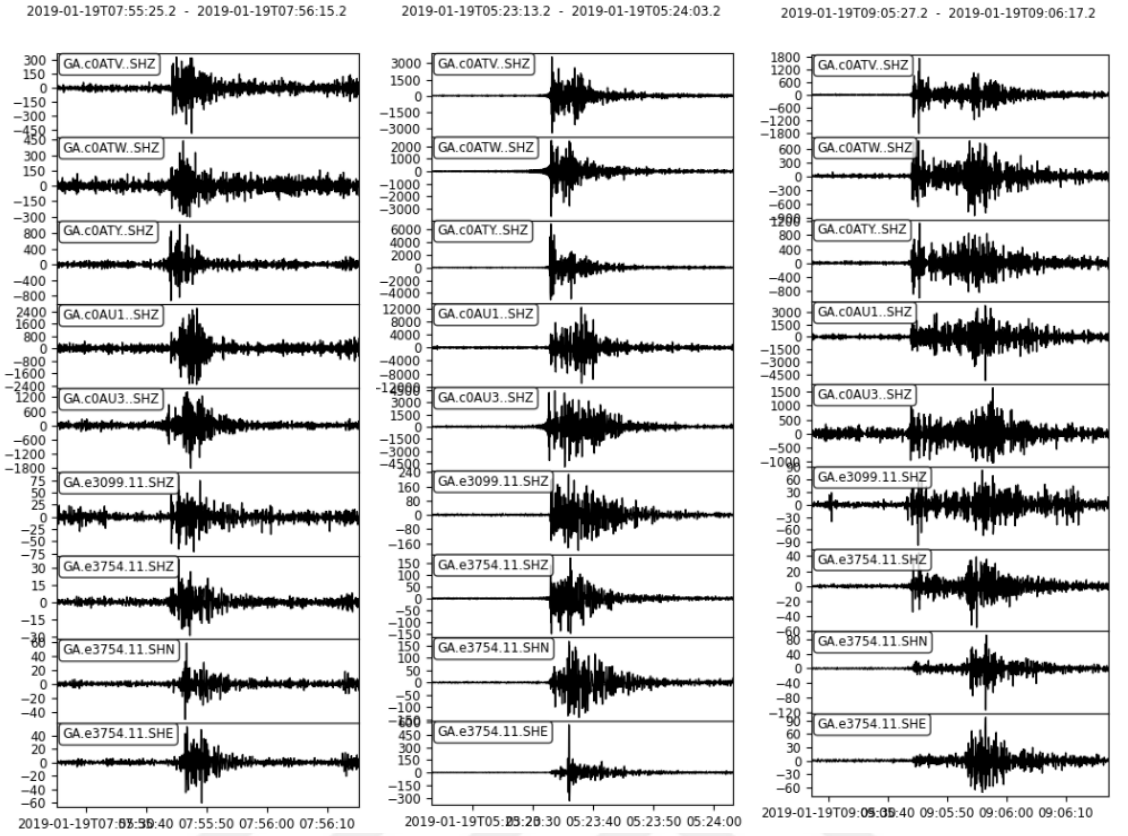

2019-01-15T00:19:39.2 - 2019-01-15T00:20:29.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-15T00:19:50 00:20:00 00:20:10 00:20:20

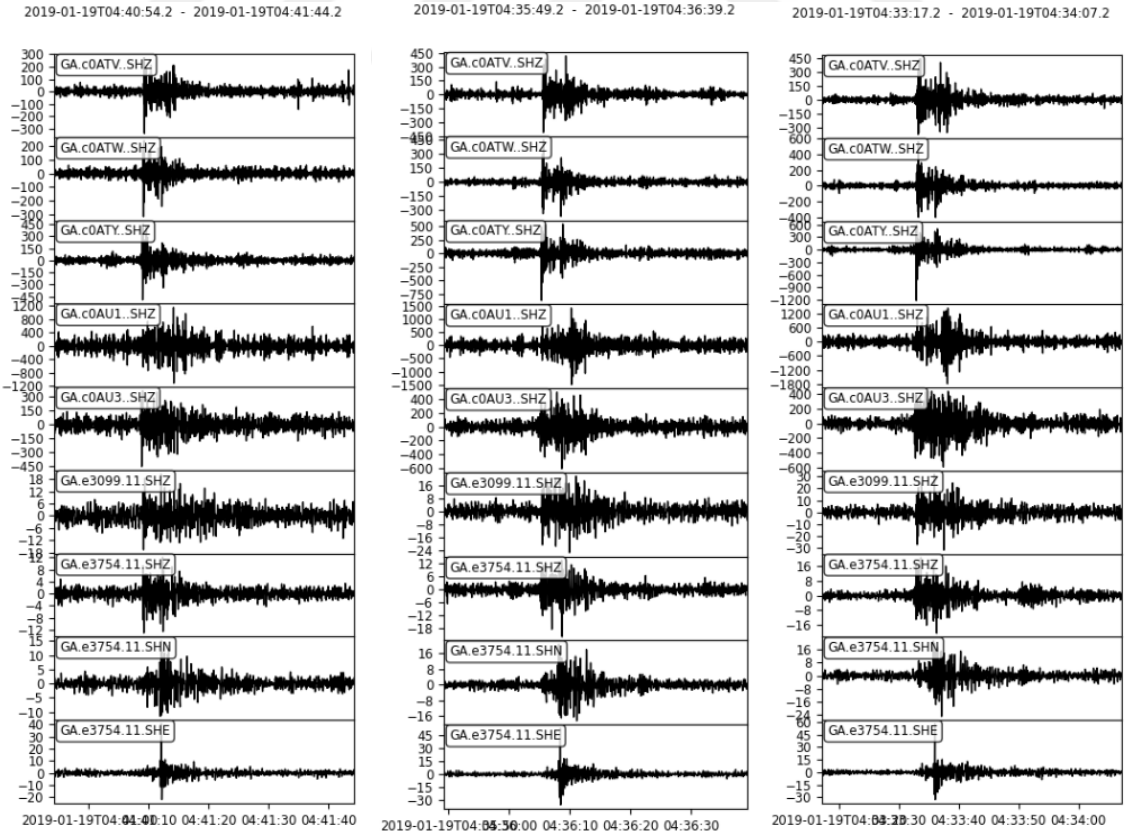

2019-01-19T18:39:33.2 - 2019-01-19T18:40:23.2
2019-01-19T18:08:42.2 - 2019-01-19T18:09:32.2
2019-01-18T18:22:18.2 - 2019-01-18T18:23:08.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-19T18:39:50 18:40:00 18:40:10 18:40:20
2019-01-19T18:09:00 18:09:10 18:09:20 18:09:30
2019-01-18T18:22:30 18:22:40 18:22:50 18:23:00

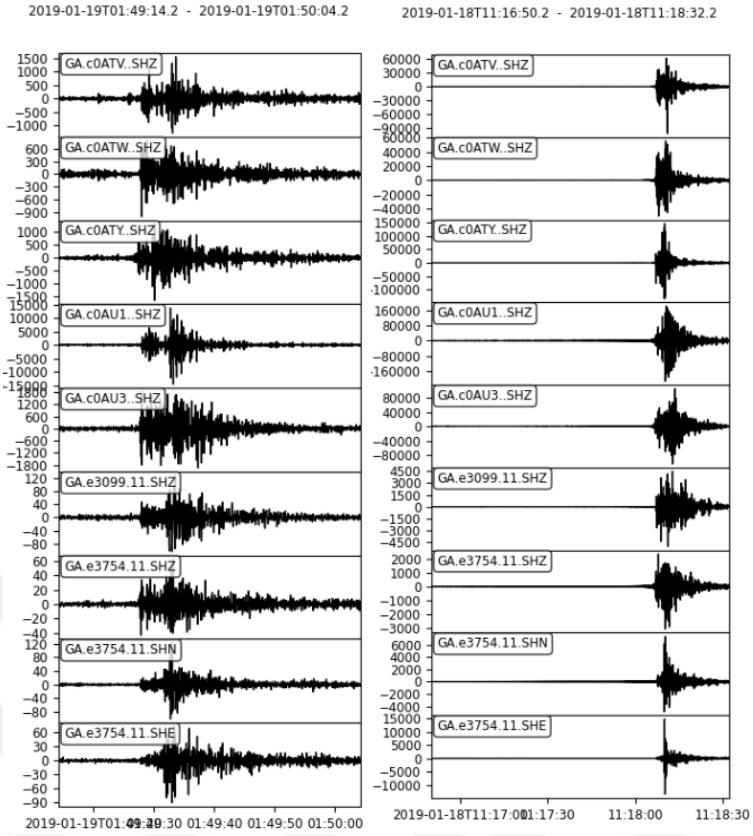

2019-01-18T22:40:20.2 - 2019-01-18T22:41:10.2
2019-01-18T19:04:02.2 - 2019-01-18T19:04:52.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-18T22:40:40 22:40:50 22:41:00 22:41:10
2019-01-18T19:04:20 19:04:30 19:04:40 19:04:50

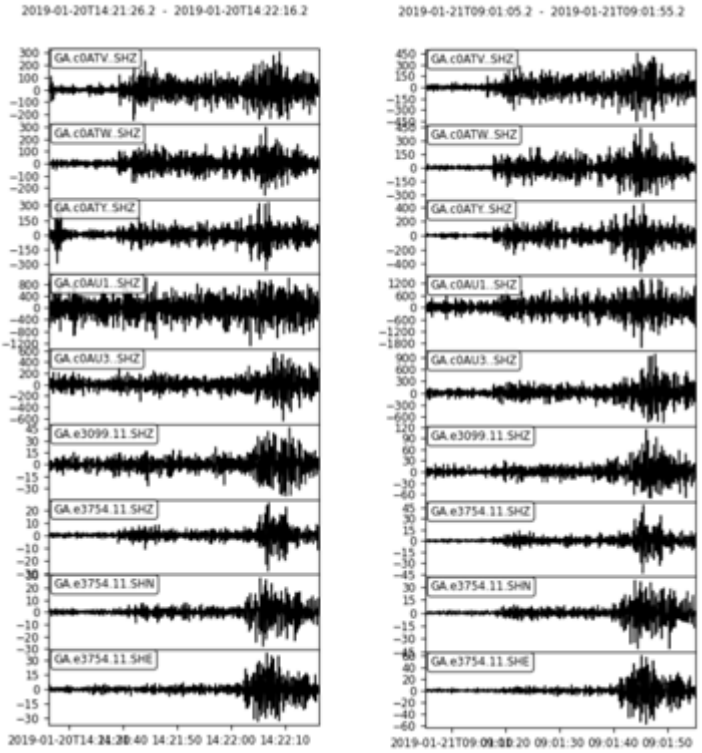

2019-01-18T13:33:41.2 - 2019-01-18T13:34:31.2
2019-01-18T12:02:31.2 - 2019-01-18T12:03:21.2
2019-01-19T12:32:54.2 - 2019-01-19T12:33:44.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

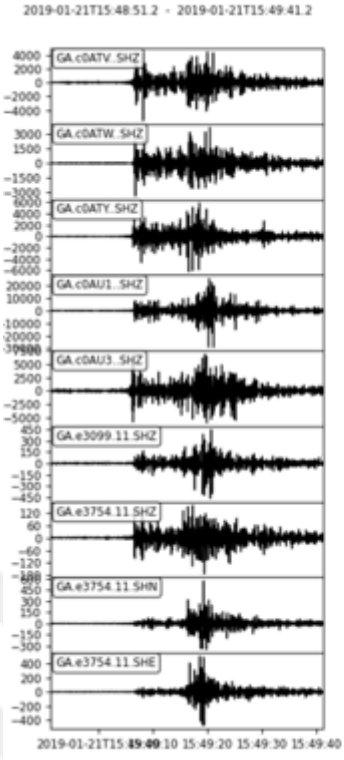

2019-01-18T18:26:52.2 - 2019-01-18T18:27:42.2
2019-01-19T05:24:55.2 - 2019-01-19T05:25:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

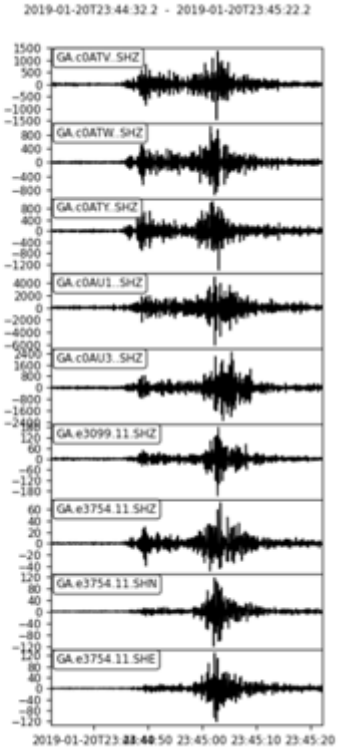

2019-01-19T07:55:25.2 - 2019-01-19T07:56:15.2
2019-01-19T05:23:13.2 - 2019-01-19T05:24:03.2
2019-01-19T09:05:27.2 - 2019-01-19T09:06:17.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

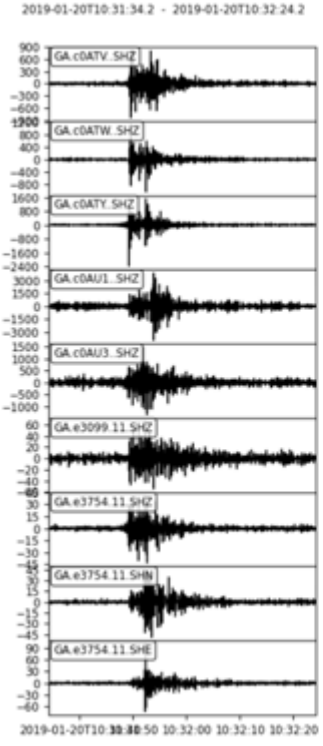

2019-01-19T04:40:54.2 - 2019-01-19T04:41:44.2
2019-01-19T04:35:49.2 - 2019-01-19T04:36:39.2
2019-01-19T04:33:17.2 - 2019-01-19T04:34:07.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

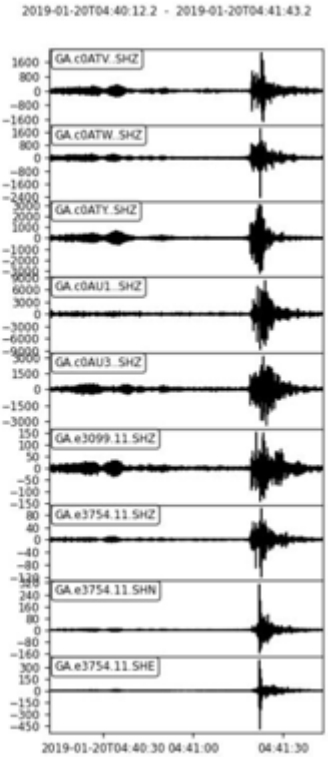

2019-01-19T01:49:14.2 - 2019-01-19T01:50:04.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-19T01:49:20 01:49:30 01:49:40 01:49:50 01:50:00
2019-01-18T11:16:50.2 - 2019-01-18T11:18:32.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-18T11:17:00 11:17:30 11:18:00 11:18:30

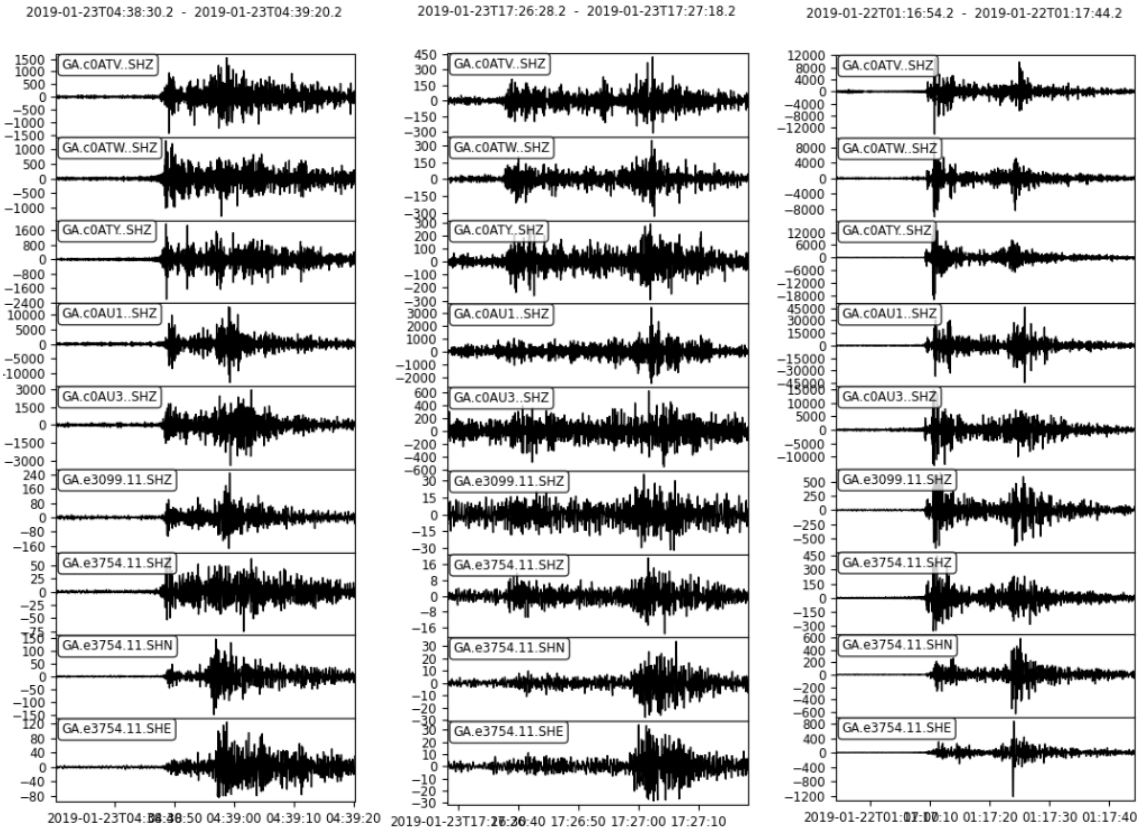

2019-01-20T14:21:26.2 - 2019-01-20T14:22:16.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-20T14:21:40 14:21:50 14:22:00 14:22:10
2019-01-21T09:01:05.2 - 2019-01-21T09:01:55.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-21T09:01:20 09:01:30 09:01:40 09:01:50

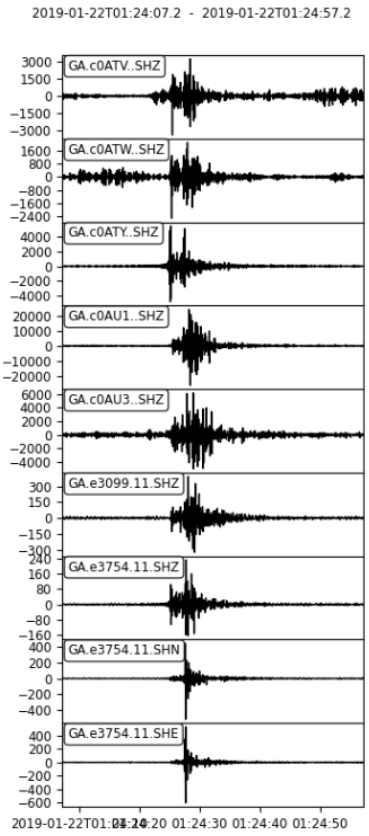

2019-01-21T15:48:51.2 - 2019-01-21T15:49:41.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-21T15:49:10 15:49:20 15:49:30 15:49:40

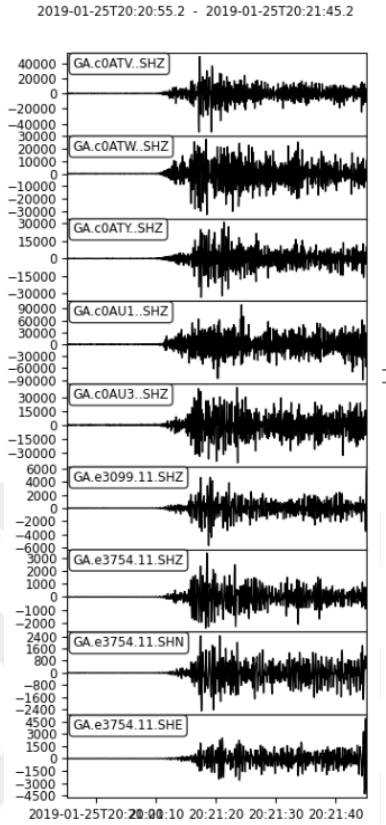

2019-01-20T23:44:32.2 - 2019-01-20T23:45:22.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-20T23:44:50 23:45:00 23:45:10 23:45:20

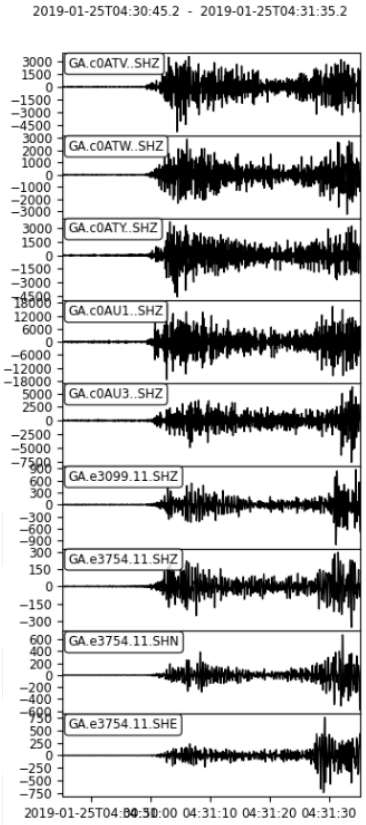

2019-01-20T10:31:34.2 - 2019-01-20T10:32:24.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-20T10:31:50 10:32:00 10:32:10 10:32:20

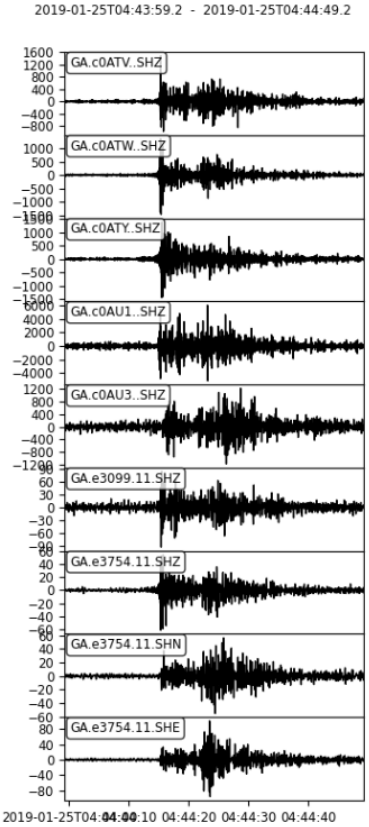

2019-01-20T04:40:12.2 - 2019-01-20T04:41:43.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-20T04:40:30 04:41:00 04:41:30

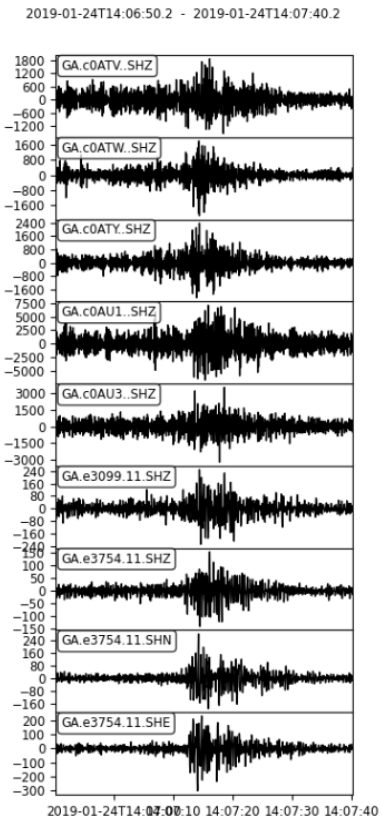

2019-01-23T04:38:30.2 - 2019-01-23T04:39:20.2
2019-01-23T17:26:28.2 - 2019-01-23T17:27:18.2
2019-01-22T01:16:54.2 - 2019-01-22T01:17:44.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-23T04:38:50 04:39:00 04:39:10 04:39:20
2019-01-23T17:26:40 17:26:50 17:27:00 17:27:10
01:17:10 01:17:20 01:17:30 01:17:40

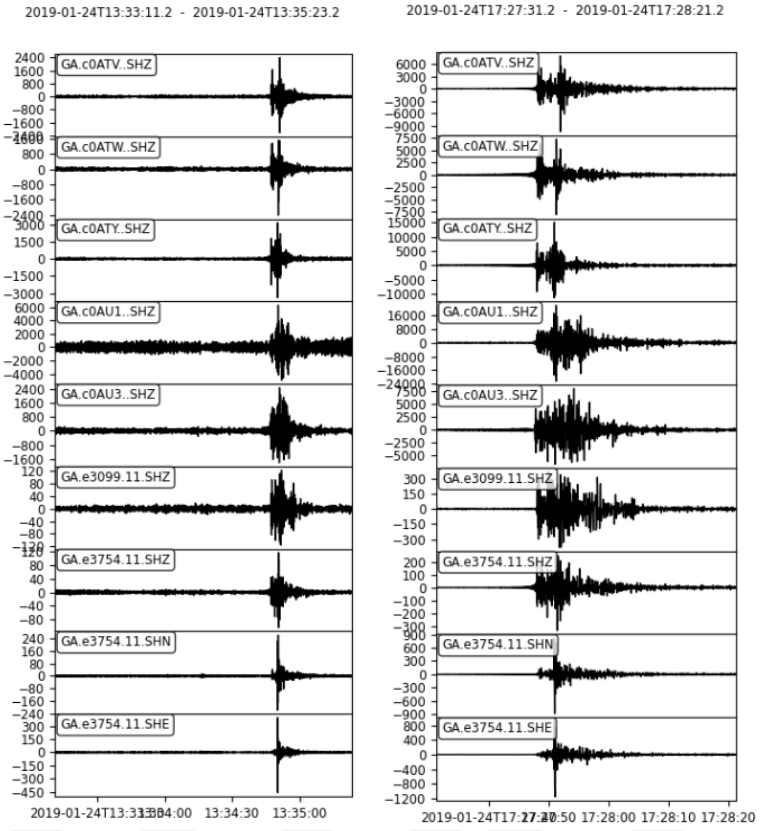

2019-01-22T01:24:07.2 - 2019-01-22T01:24:57.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
01:24:20 01:24:30 01:24:40 01:24:50

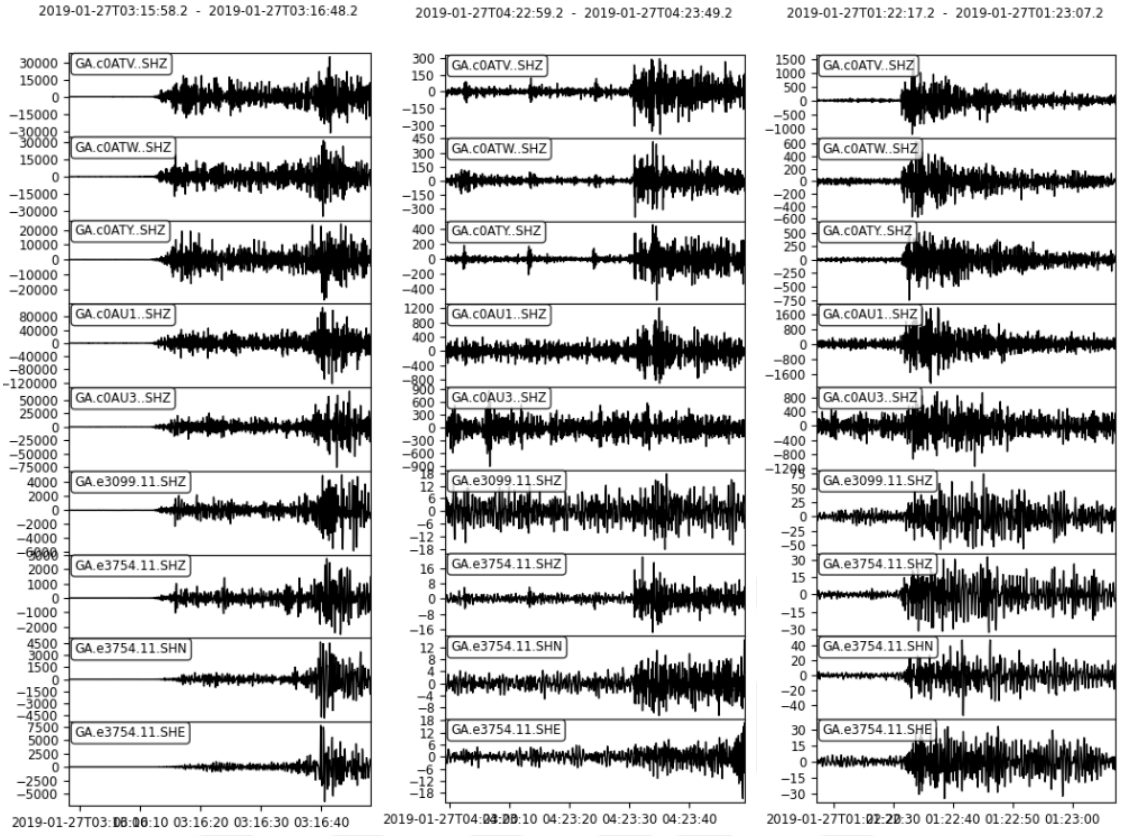

2019-01-25T20:20:55.2 - 2019-01-25T20:21:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-25T20:20:10 20:21:20 20:21:30 20:21:40

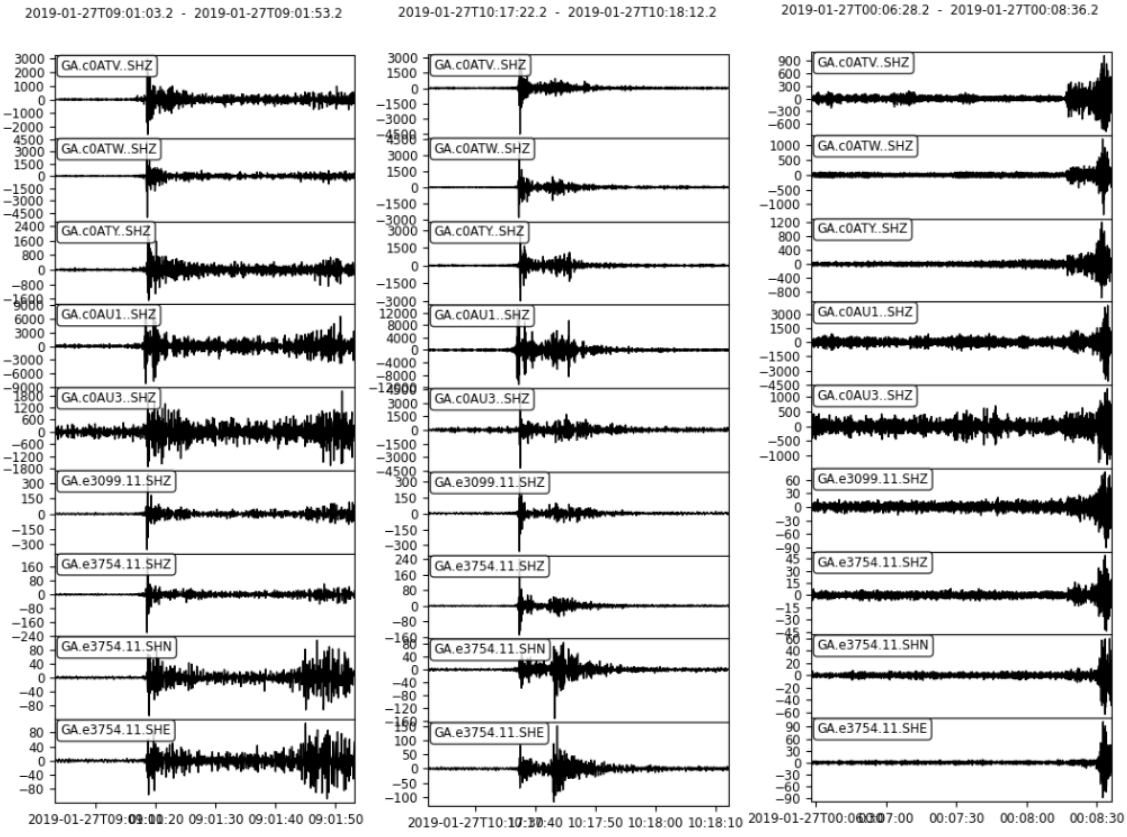

2019-01-25T04:30:45.2 - 2019-01-25T04:31:35.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-25T04:30:50 04:31:00 04:31:10 04:31:20 04:31:30

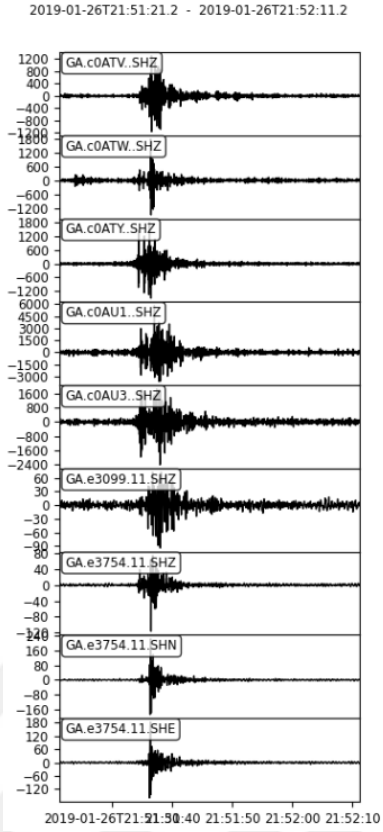

2019-01-25T04:43:59.2 - 2019-01-25T04:44:49.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-25T04:44:00 04:44:10 04:44:20 04:44:30 04:44:40

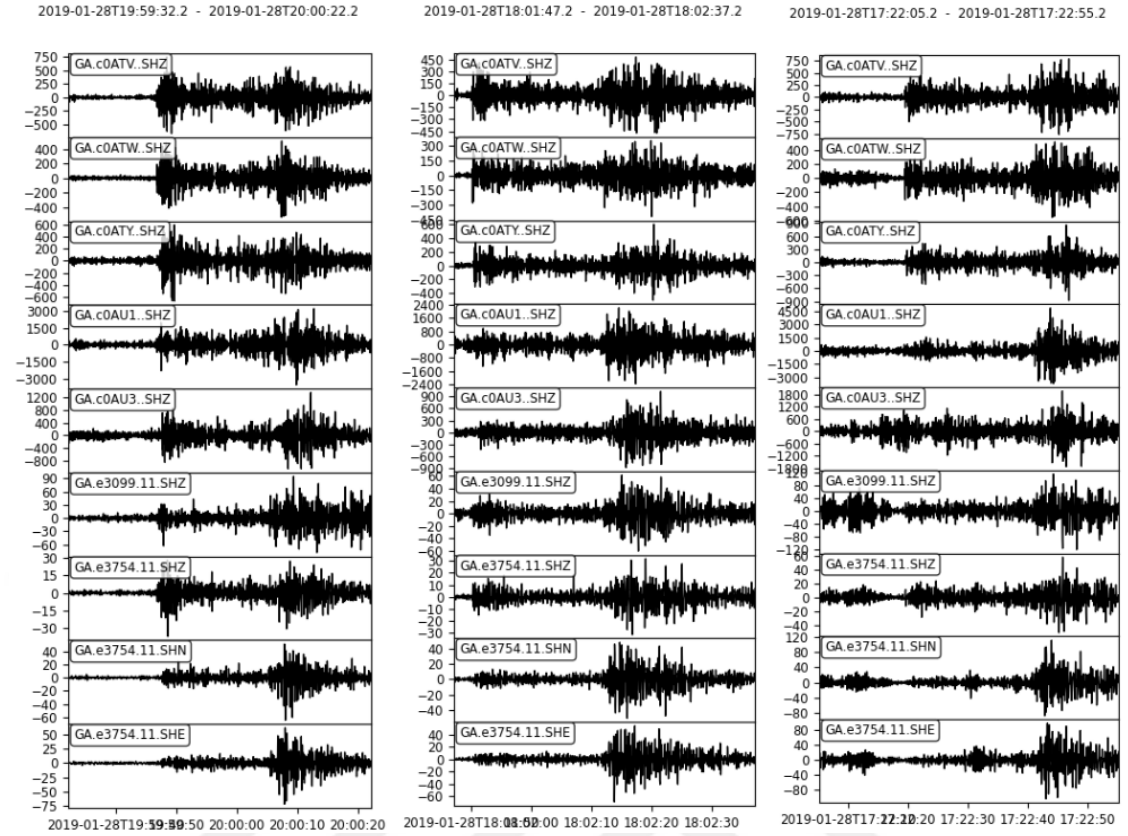

2019-01-24T14:06:50.2 - 2019-01-24T14:07:40.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-24T14:07:00 14:07:10 14:07:20 14:07:30 14:07:40

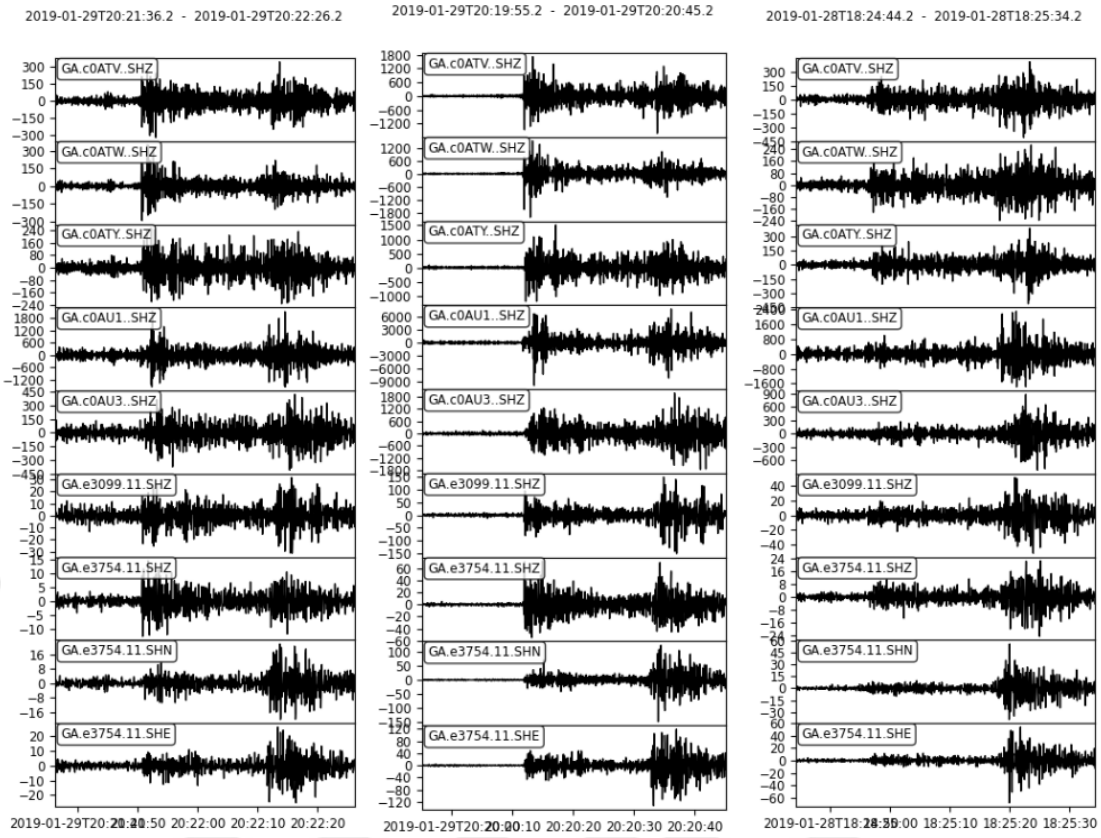

2019-01-24T13:33:11.2 - 2019-01-24T13:35:23.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
13:34:00
13:34:30
13:35:00
2019-01-24T17:27:31.2 - 2019-01-24T17:28:21.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
17:28:00
17:28:10
17:28:20

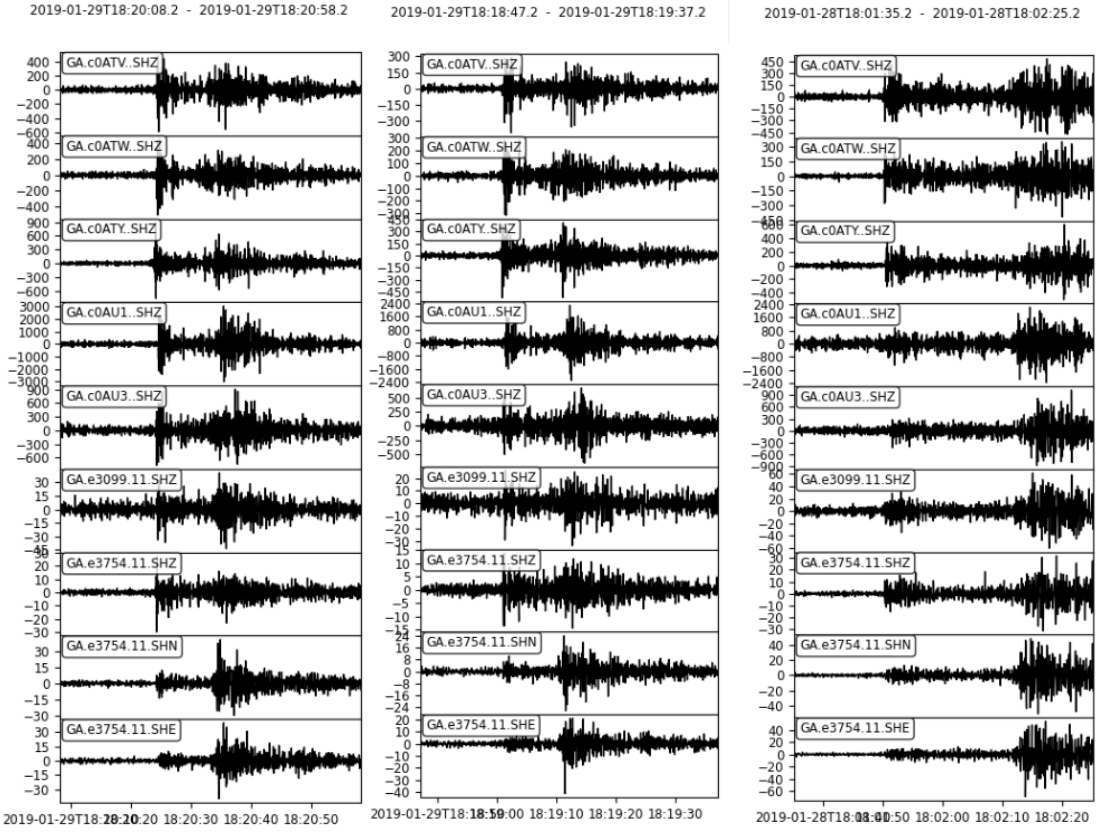

2019-01-27T03:15:58.2 - 2019-01-27T03:16:48.2
2019-01-27T04:22:59.2 - 2019-01-27T04:23:49.2
2019-01-27T01:22:17.2 - 2019-01-27T01:23:07.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

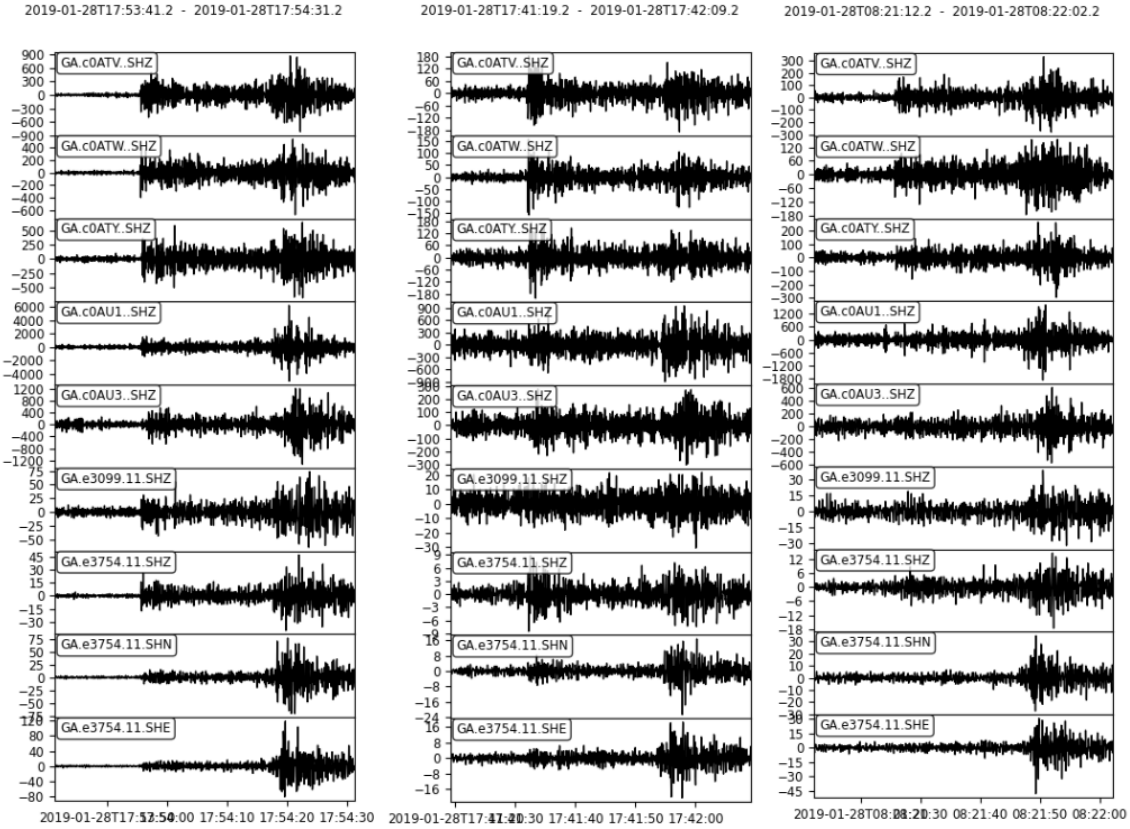

2019-01-27T09:01:03.2 - 2019-01-27T09:01:53.2
2019-01-27T10:17:22.2 - 2019-01-27T10:18:12.2
2019-01-27T00:06:28.2 - 2019-01-27T00:08:36.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

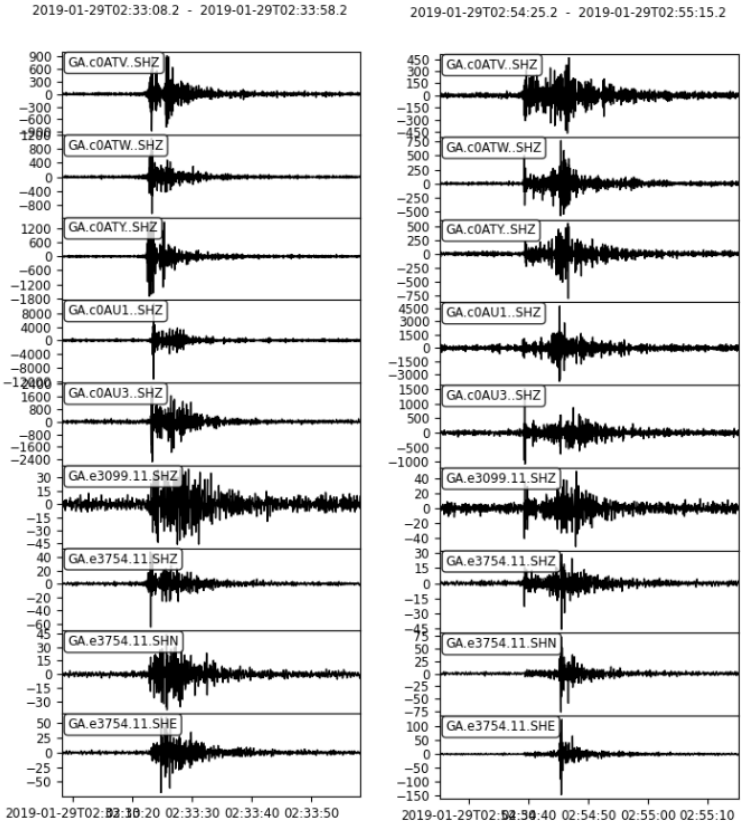

2019-01-26T21:51:21.2 - 2019-01-26T21:52:11.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-26T21:51:30
21:51:40
21:51:50
21:52:00
21:52:10

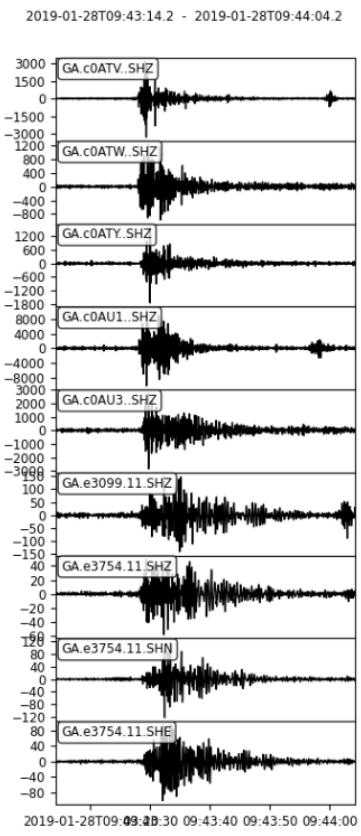

2019-01-28T19:59:32.2 - 2019-01-28T20:00:22.2
2019-01-28T18:01:47.2 - 2019-01-28T18:02:37.2
2019-01-28T17:22:05.2 - 2019-01-28T17:22:55.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-28T16:58:49.2 - 2019-01-28T16:59:39.2
2019-01-28T07:50:49.2 - 2019-01-28T07:51:39.2
2019-01-29T01:48:26.2 - 2019-01-29T01:49:16.2

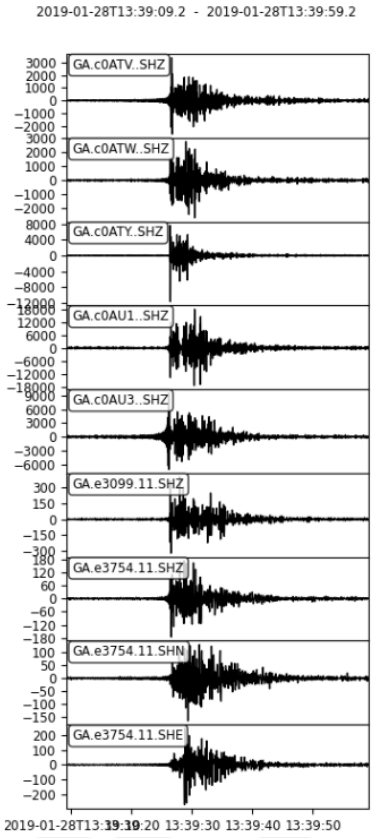

2019-01-29T20:21:36.2 - 2019-01-29T20:22:26.2
2019-01-29T20:19:55.2 - 2019-01-29T20:20:45.2
2019-01-28T18:24:44.2 - 2019-01-28T18:25:34.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-29T20:22:00 20:22:10 20:22:20
2019-01-29T20:20:00 20:20:10 20:20:20 20:20:30 20:20:40
2019-01-28T18:25:00 18:25:10 18:25:20 18:25:30

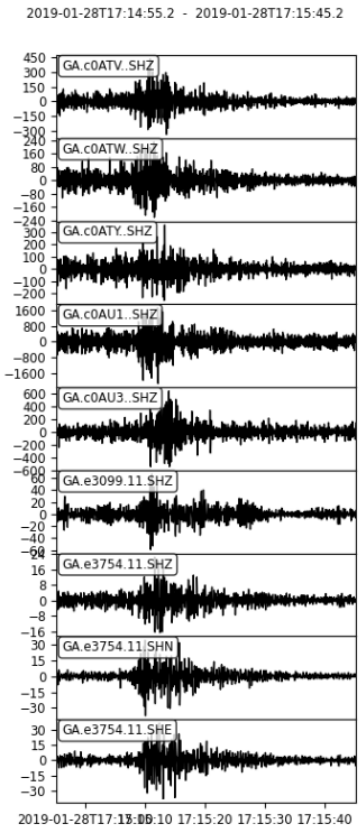

2019-01-29T18:20:08.2 - 2019-01-29T18:20:58.2
2019-01-29T18:18:47.2 - 2019-01-29T18:19:37.2
2019-01-28T18:01:35.2 - 2019-01-28T18:02:25.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-29T18:20:20 18:20:30 18:20:40 18:20:50
2019-01-29T18:19:00 18:19:10 18:19:20 18:19:30
2019-01-28T18:02:00 18:02:10 18:02:20

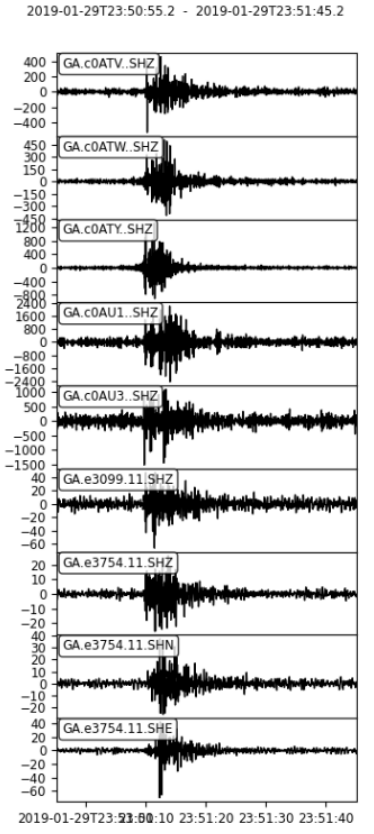

2019-01-28T17:53:41.2 - 2019-01-28T17:54:31.2
2019-01-28T17:41:19.2 - 2019-01-28T17:42:09.2
2019-01-28T08:21:12.2 - 2019-01-28T08:22:02.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-28T17:54:00 17:54:10 17:54:20 17:54:30
2019-01-28T17:41:30 17:41:40 17:41:50 17:42:00
2019-01-28T08:21:30 08:21:40 08:21:50 08:22:00

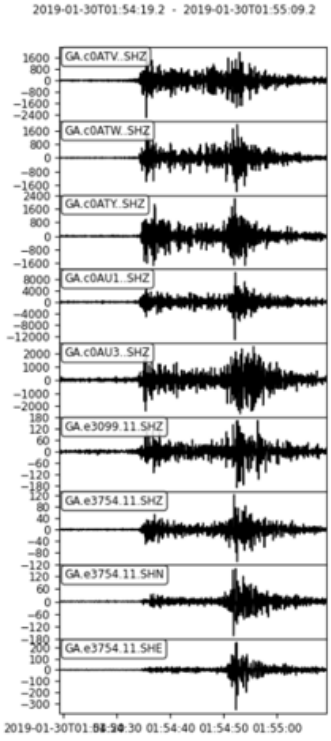

2019-01-29T02:33:08.2 - 2019-01-29T02:33:58.2
2019-01-29T02:54:25.2 - 2019-01-29T02:55:15.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-29T02:33:20 02:33:30 02:33:40 02:33:50
2019-01-29T02:54:40 02:54:50 02:55:00 02:55:10

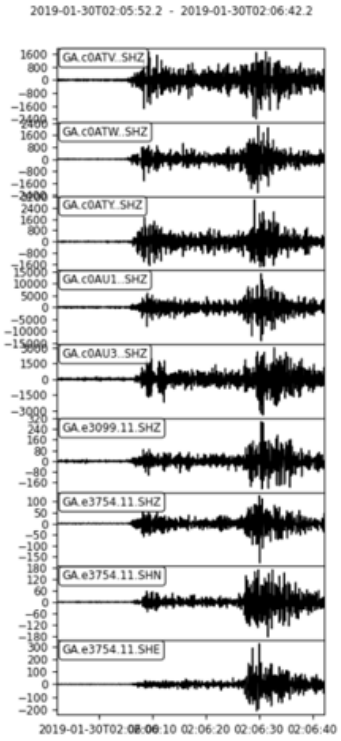

2019-01-28T09:43:14.2 - 2019-01-28T09:44:04.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-28T09:43:30 09:43:40 09:43:50 09:44:00

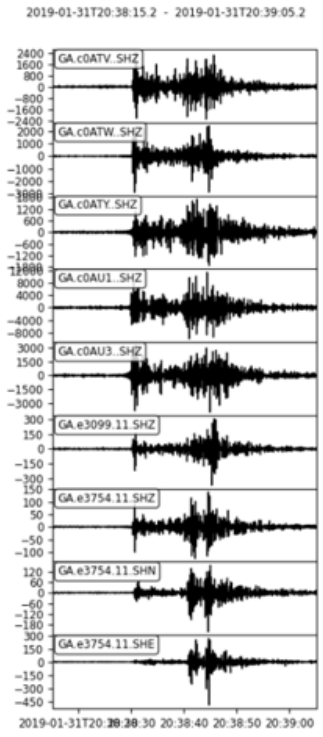

2019-01-28T13:39:09.2 - 2019-01-28T13:39:59.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-28T13:39:30 13:39:40 13:39:50

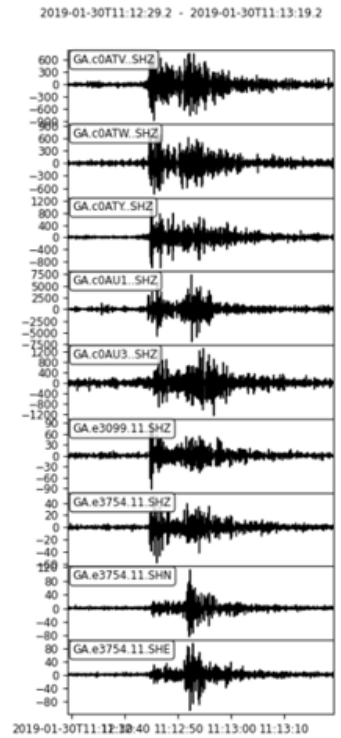

2019-01-28T17:14:55.2 - 2019-01-28T17:15:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-28T17:15:10 17:15:20 17:15:30 17:15:40

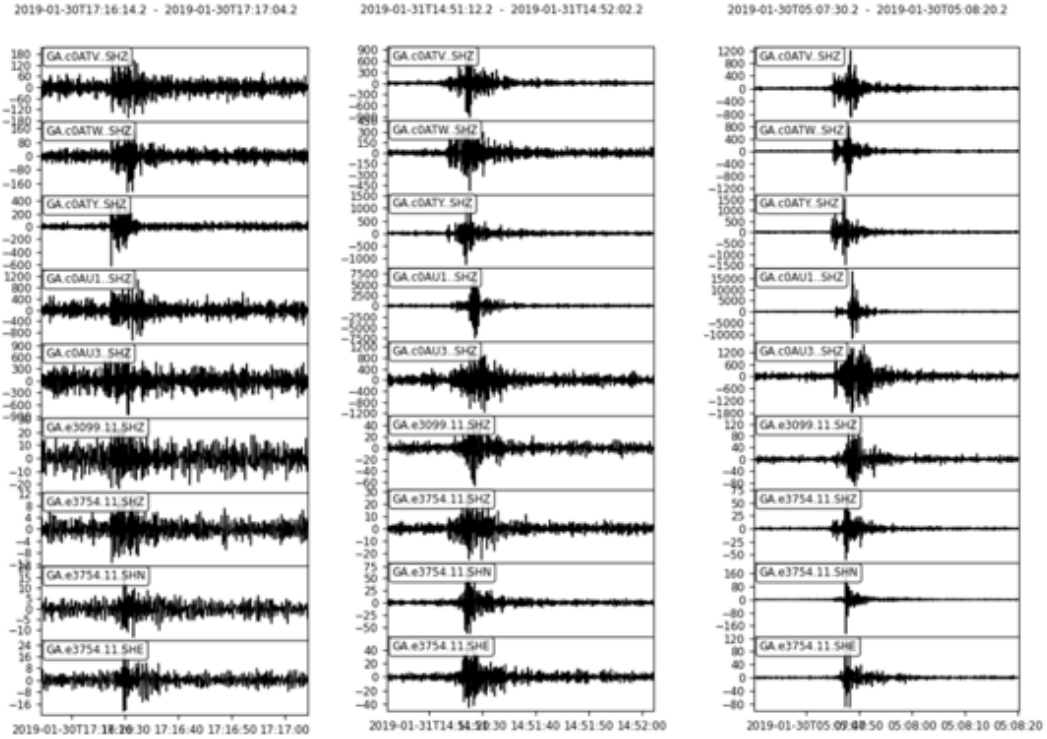

2019-01-29T23:50:55.2 - 2019-01-29T23:51:45.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-29T23:51:10 23:51:20 23:51:30 23:51:40

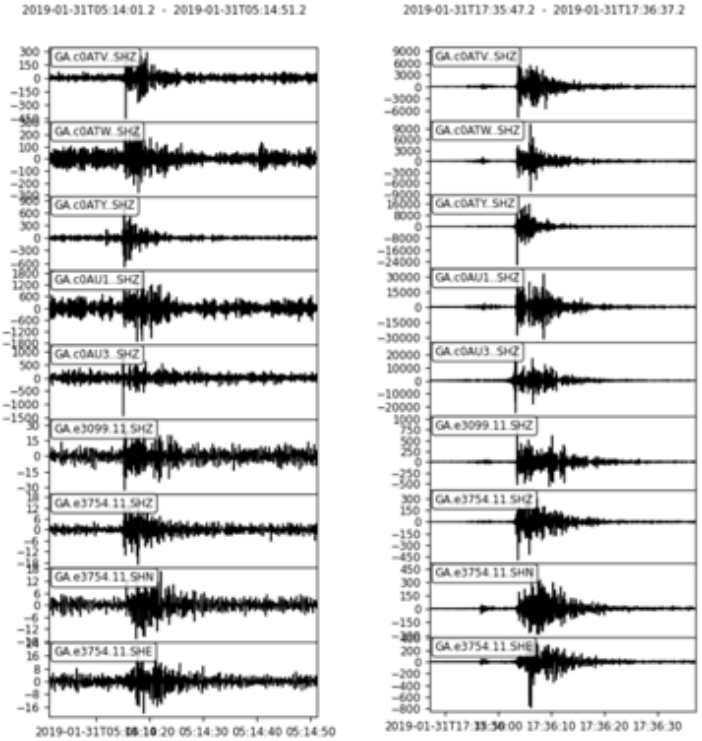

2019-01-30T01:54:19.2 - 2019-01-30T01:55:09.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-30T01:54:30 01:54:40 01:54:50 01:55:00

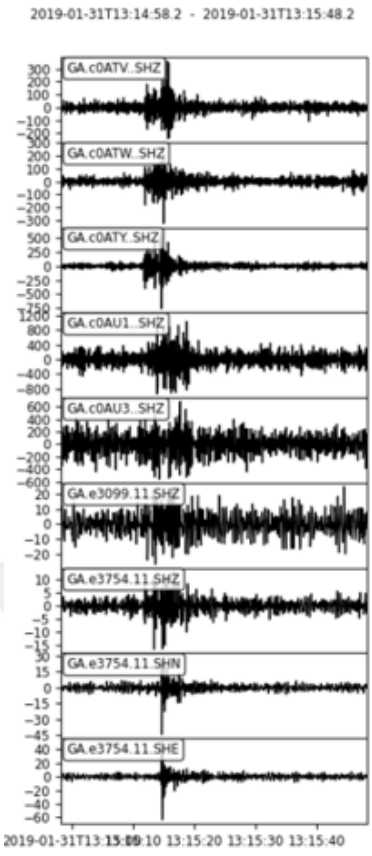

2019-01-30T02:05:52.2 - 2019-01-30T02:06:42.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-30T02:06:10 02:06:20 02:06:30 02:06:40

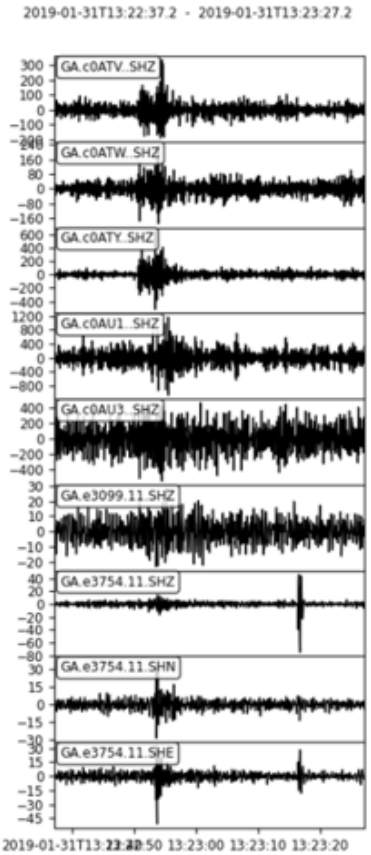

2019-01-31T20:38:15.2 - 2019-01-31T20:39:05.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-31T20:38:30 20:38:40 20:38:50 20:39:00

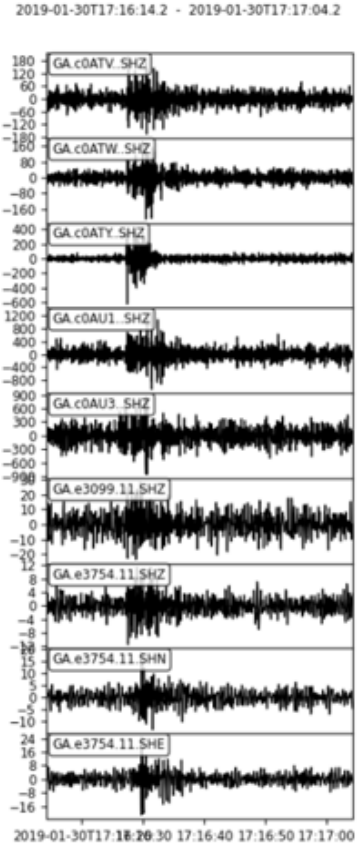

2019-01-30T11:12:29.2 - 2019-01-30T11:13:19.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-30T11:12:40 11:12:50 11:13:00 11:13:10


2019-01-30T17:16:14.2 - 2019-01-30T17:17:04.2
2019-01-31T14:51:12.2 - 2019-01-31T14:52:02.2
2019-01-30T05:07:30.2 - 2019-01-30T05:08:20.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-30T17:16:30 17:16:40 17:16:50 17:17:00
2019-01-31T14:51:30 14:51:40 14:51:50 14:52:00
2019-01-30T05:08:00 05:08:10 05:08:20

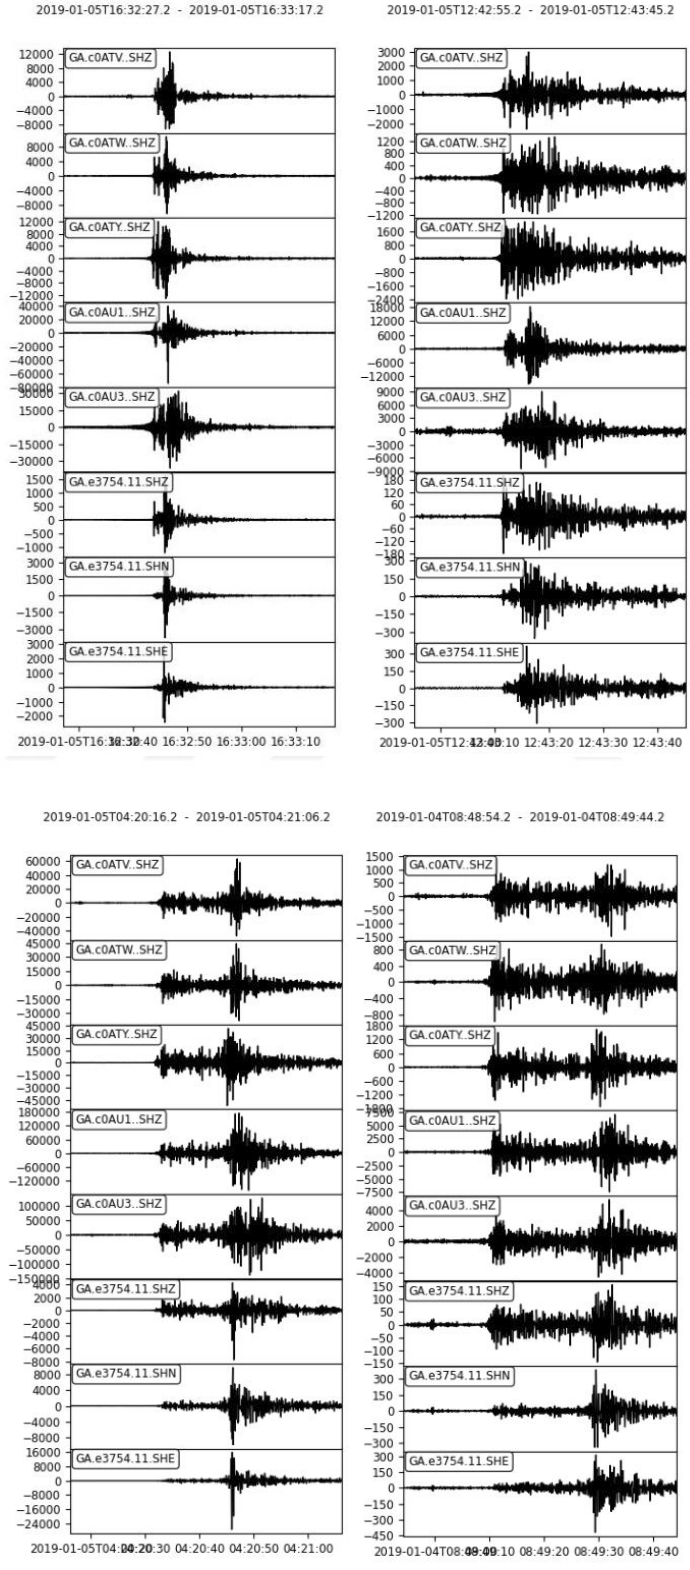

2019-01-31T05:14:01.2 - 2019-01-31T05:14:51.2
2019-01-31T17:35:47.2 - 2019-01-31T17:36:37.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-31T05:14:20 05:14:30 05:14:40 05:14:50
2019-01-31T17:36:10 17:36:20 17:36:30

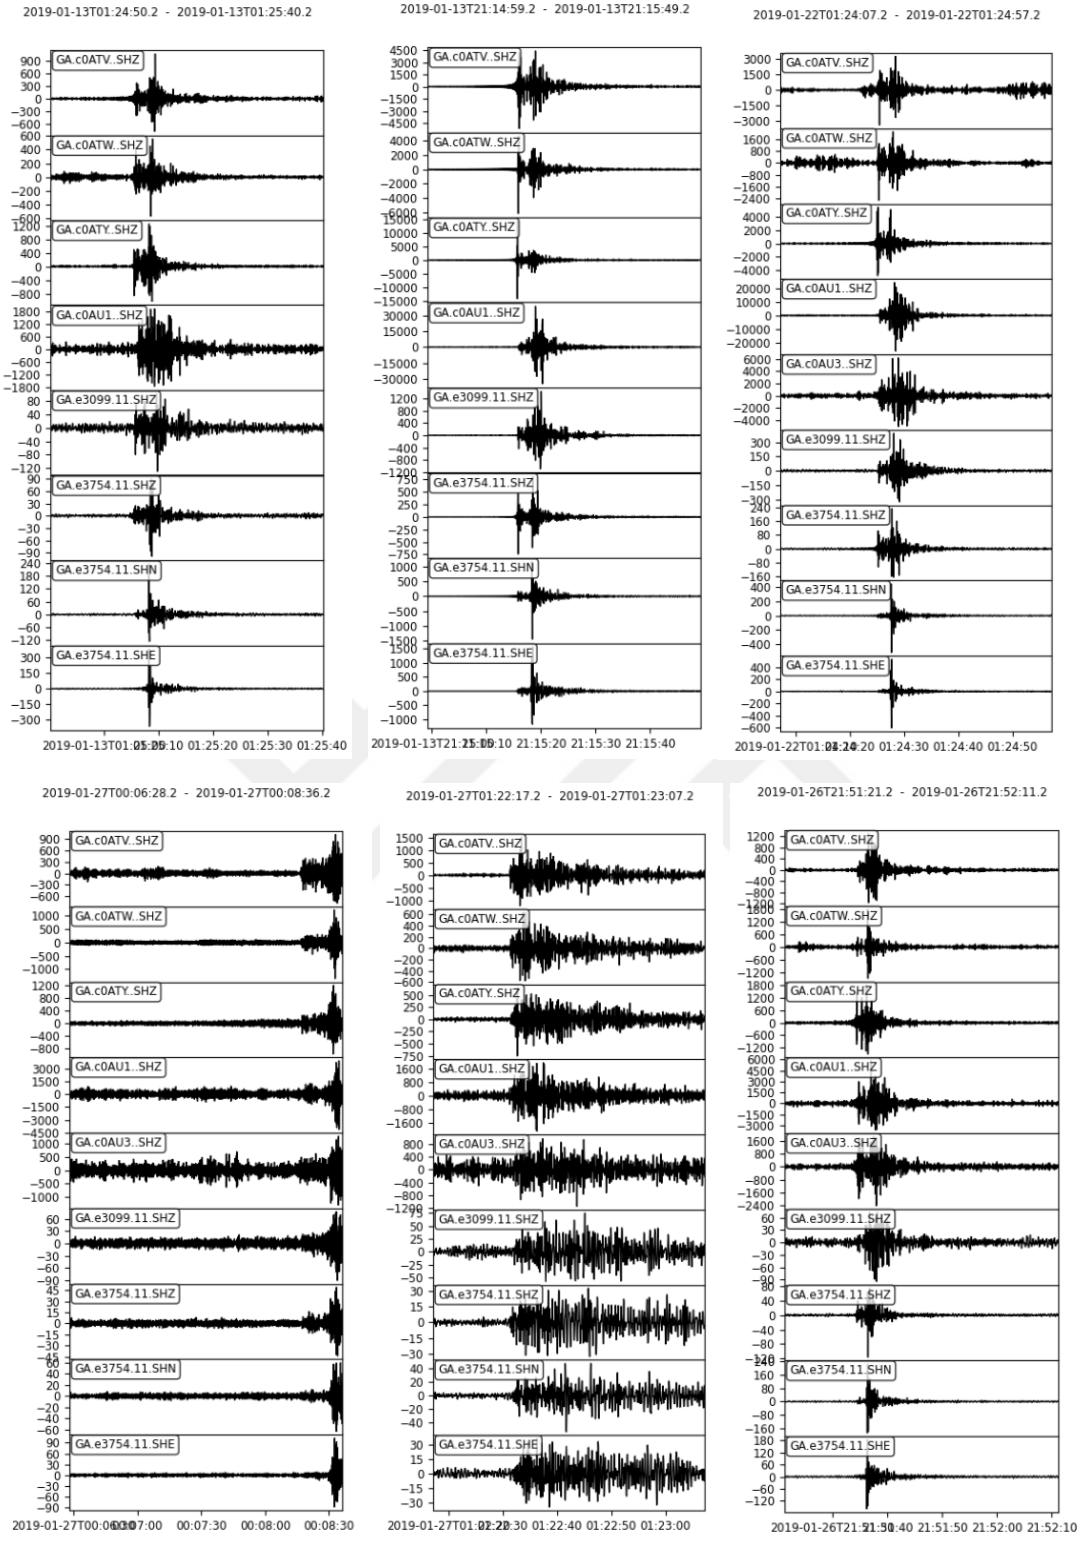

2019-01-31T13:14:58.2 - 2019-01-31T13:15:48.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-31T13:15:10 13:15:20 13:15:30 13:15:40

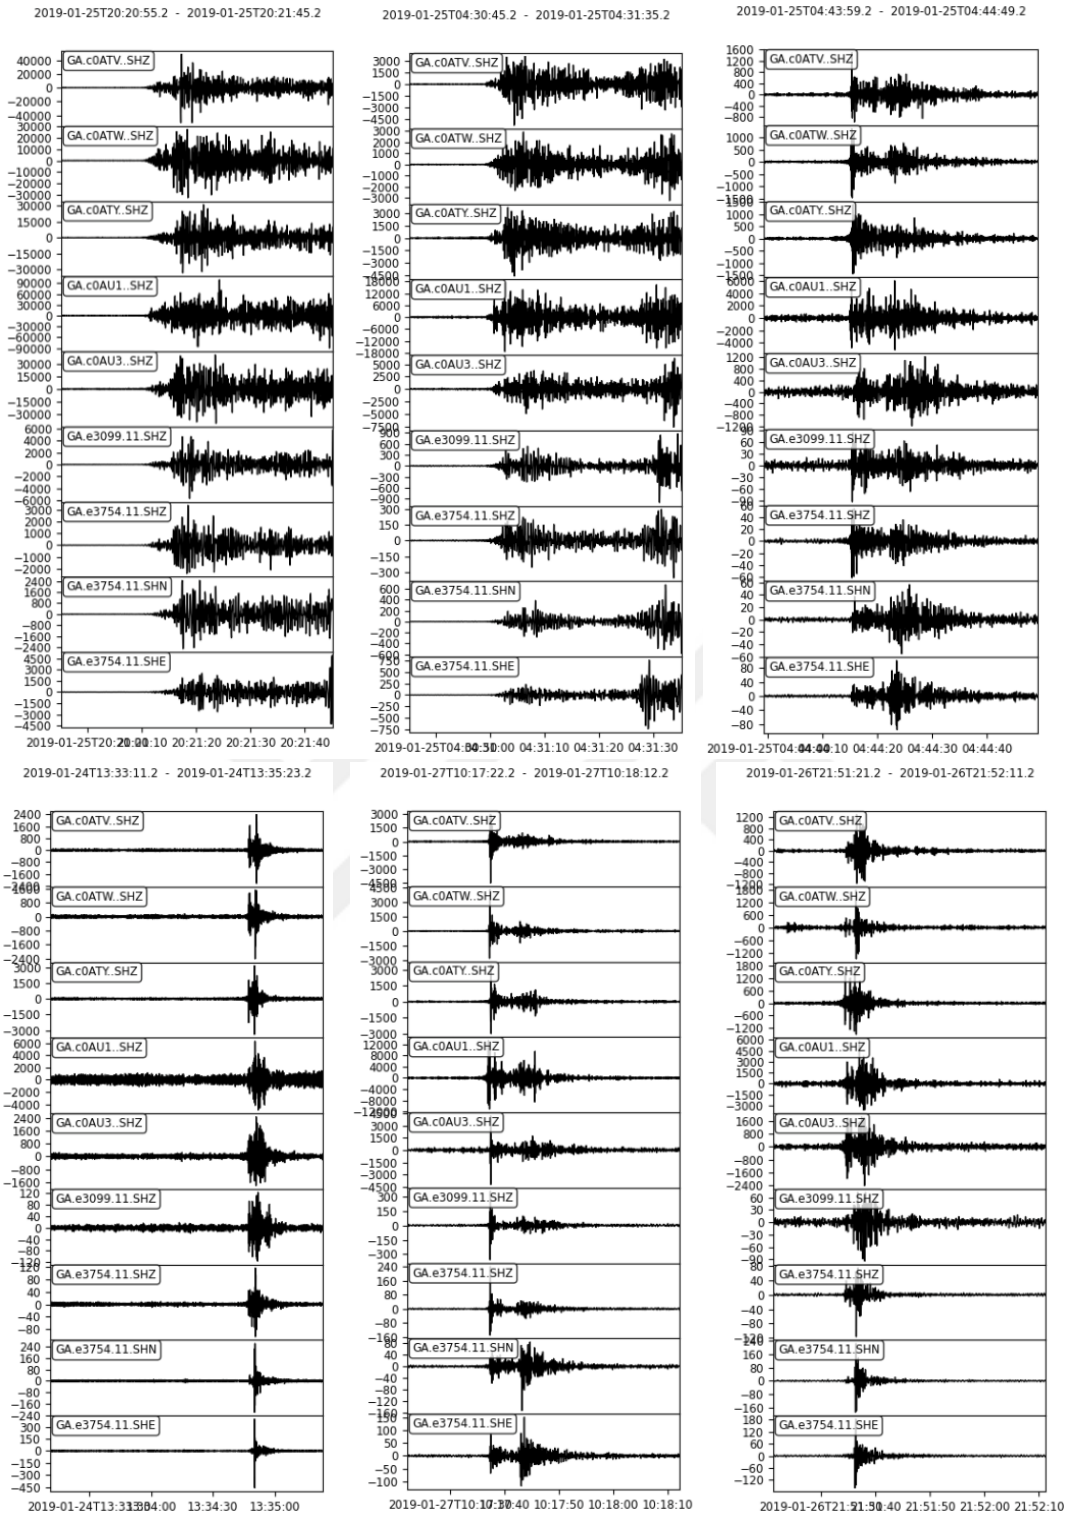

2019-01-31T13:22:37.2 - 2019-01-31T13:23:27.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
13:23:00 13:23:10 13:23:20

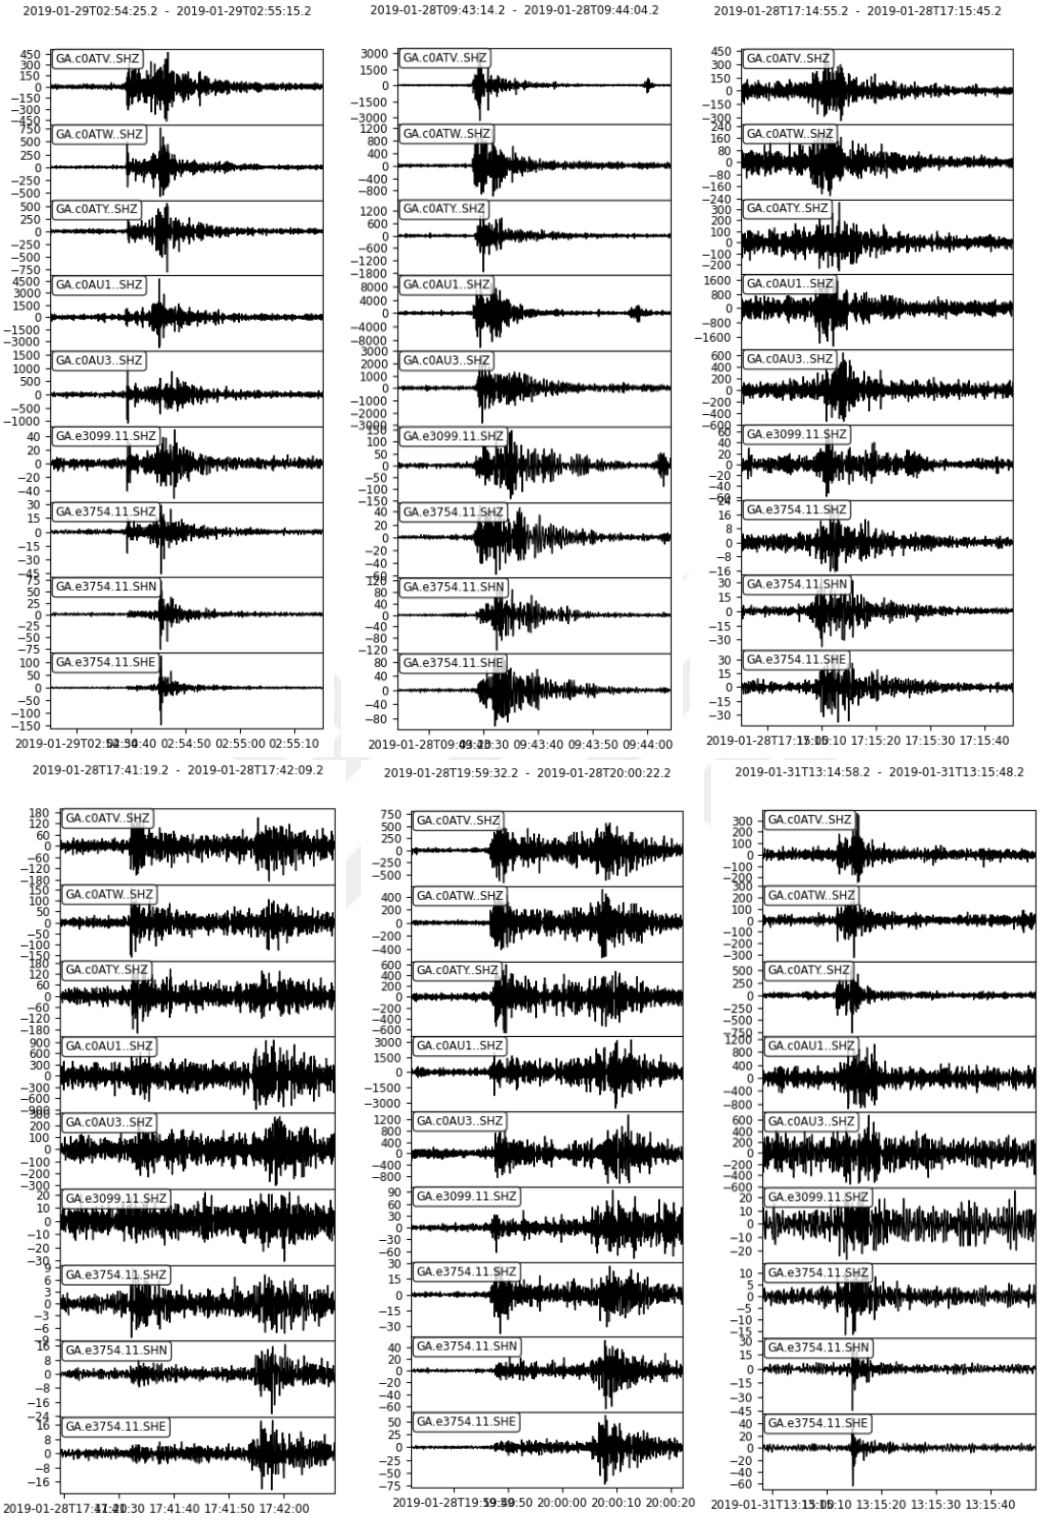

2019-01-30T17:16:14.2 - 2019-01-30T17:17:04.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
17:16:40 17:16:50 17:17:00

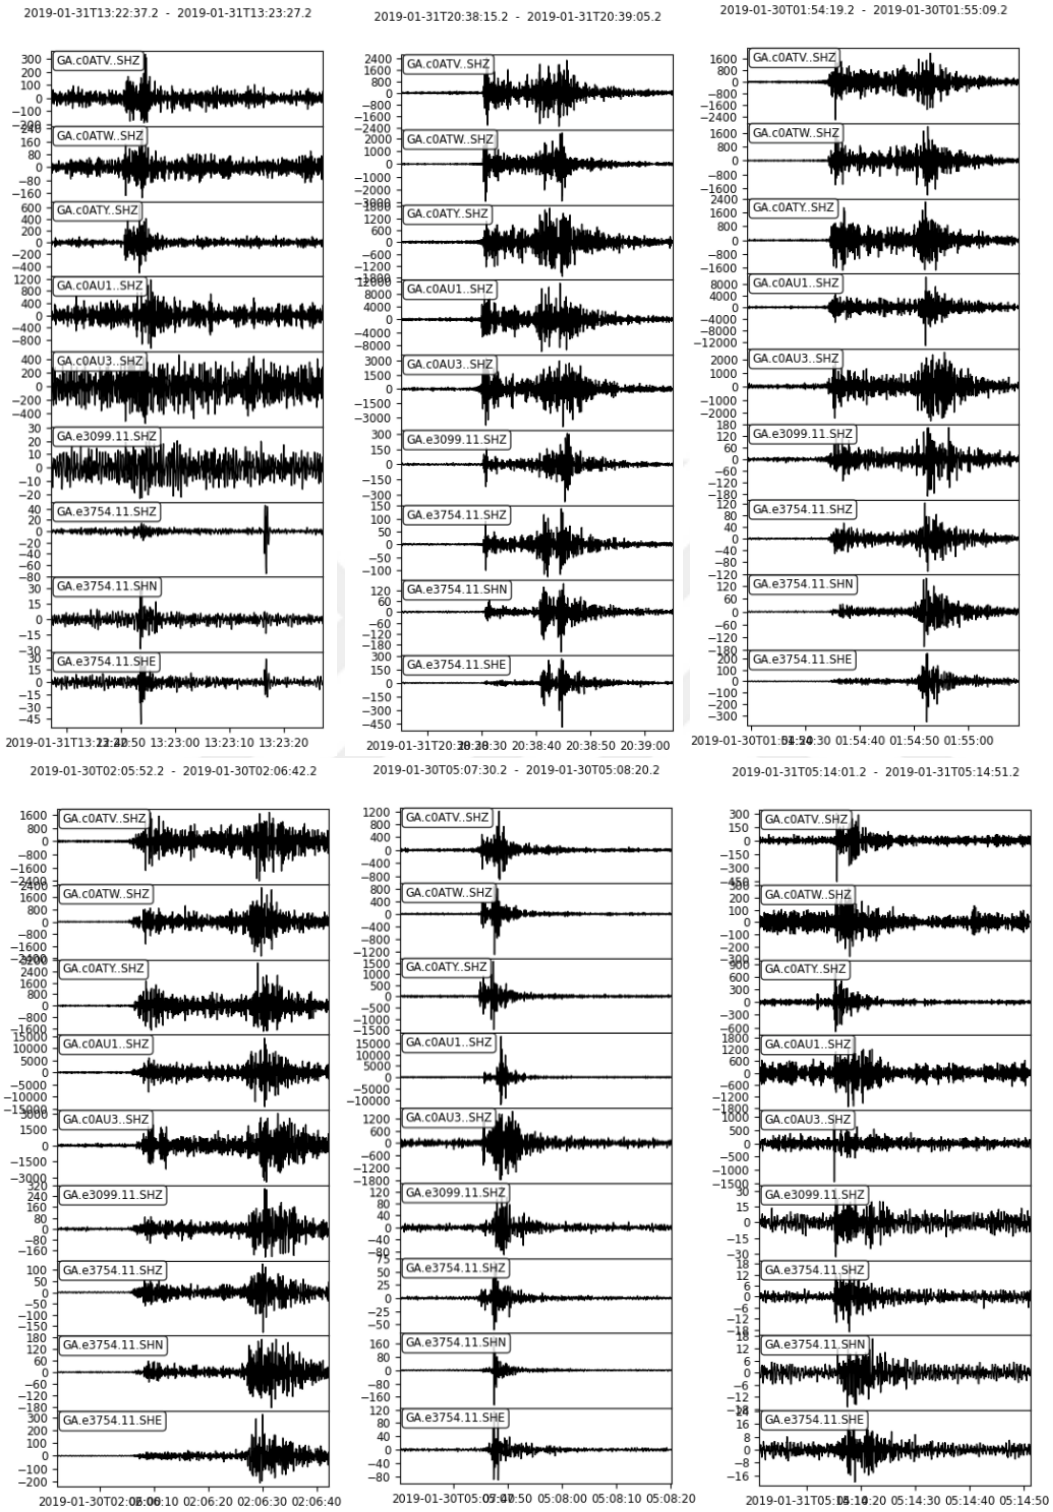
EK 2. Sadece *r*=4 *v*=2 parametresi ile yapılan FAST algılamada bulunan 31 deprem aşağıda yer almaktadır. Yapılan katalog taramasında tespit edilen 31 depremin 12'si istasyonlara yakın meydana gelen depremler (kısa ts-tp zamanları, Güzelköy açıkları-Tekirdağ) iken 19'u istasyonlardan uzakta (daha uzun ts-tp zamanları) meydana gelen depremlerdir.

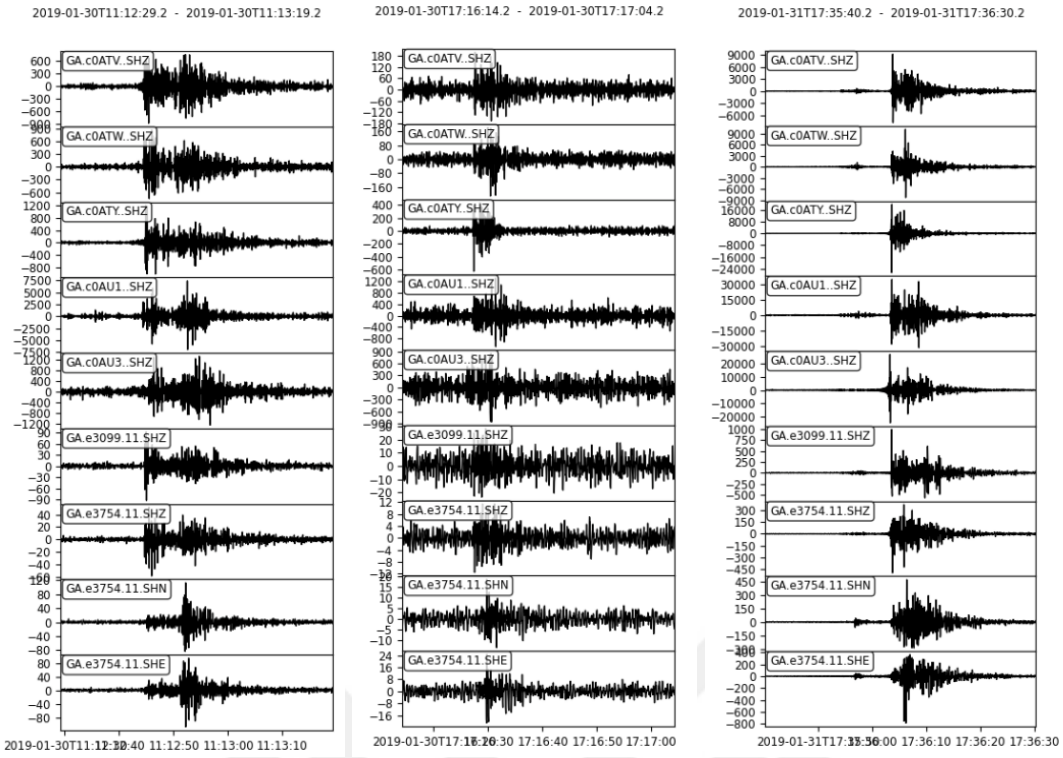



2019-01-13T01:24:50.2 - 2019-01-13T01:25:40.2
2019-01-13T21:14:59.2 - 2019-01-13T21:15:49.2
2019-01-22T01:24:07.2 - 2019-01-22T01:24:57.2
2019-01-27T00:06:28.2 - 2019-01-27T00:08:36.2
2019-01-27T01:22:17.2 - 2019-01-27T01:23:07.2
2019-01-26T21:51:21.2 - 2019-01-26T21:52:11.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE

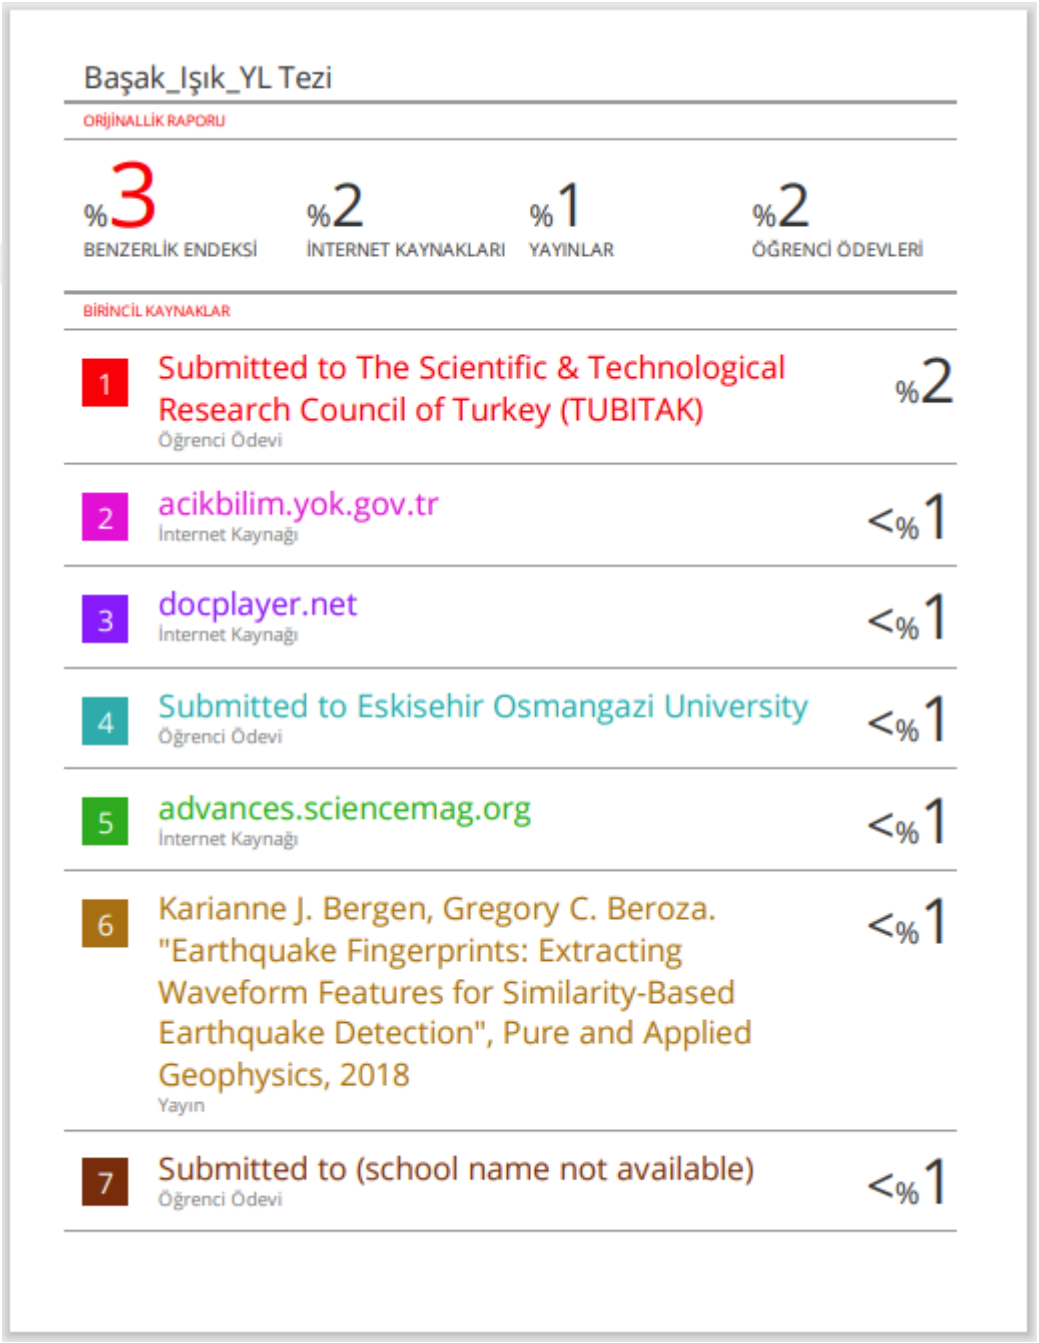

2019-01-25T20:20:55.2 - 2019-01-25T20:21:45.2
2019-01-25T04:30:45.2 - 2019-01-25T04:31:35.2
2019-01-25T04:43:59.2 - 2019-01-25T04:44:49.2
2019-01-24T13:33:11.2 - 2019-01-24T13:35:23.2
2019-01-27T10:17:22.2 - 2019-01-27T10:18:12.2
2019-01-26T21:51:21.2 - 2019-01-26T21:52:11.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE


2019-01-29T02:54:25.2 - 2019-01-29T02:55:15.2
2019-01-28T09:43:14.2 - 2019-01-28T09:44:04.2
2019-01-28T17:14:55.2 - 2019-01-28T17:15:45.2
2019-01-28T17:41:19.2 - 2019-01-28T17:42:09.2
2019-01-28T19:59:32.2 - 2019-01-28T20:00:22.2
2019-01-31T13:14:58.2 - 2019-01-31T13:15:48.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE


2019-01-31T13:22:37.2 - 2019-01-31T13:23:27.2
2019-01-31T20:38:15.2 - 2019-01-31T20:39:05.2
2019-01-30T01:54:19.2 - 2019-01-30T01:55:09.2
2019-01-30T02:05:52.2 - 2019-01-30T02:06:42.2
2019-01-30T05:07:30.2 - 2019-01-30T05:08:20.2
2019-01-31T05:14:01.2 - 2019-01-31T05:14:51.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE


2019-01-30T11:12:29.2 - 2019-01-30T11:13:19.2
2019-01-30T17:16:14.2 - 2019-01-30T17:17:04.2
2019-01-31T17:35:40.2 - 2019-01-31T17:36:30.2
GA.c0ATV..SHZ
GA.c0ATW..SHZ
GA.c0ATY..SHZ
GA.c0AU1..SHZ
GA.c0AU3..SHZ
GA.e3099.11.SHZ
GA.e3754.11.SHZ
GA.e3754.11.SHN
GA.e3754.11.SHE
2019-01-30T11:12:40 11:12:50 11:13:00 11:13:10
2019-01-30T17:16:30 17:16:40 17:16:50 17:17:00
2019-01-31T17:36:00 17:36:10 17:36:20 17:36:30

İNTİHAL RAPORU İLK SAYFASI



Başak_Işık_YL Tezi

ORİJİNALLİK RAPORU

%3	%2	%1	%2
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%2
2	acikbilim.yok.gov.tr İnternet Kaynağı	<%1
3	docplayer.net İnternet Kaynağı	<%1
4	Submitted to Eskisehir Osmangazi University Öğrenci Ödevi	<%1
5	advances.sciencemag.org İnternet Kaynağı	<%1
6	Karianne J. Bergen, Gregory C. Beroza. "Earthquake Fingerprints: Extracting Waveform Features for Similarity-Based Earthquake Detection", Pure and Applied Geophysics, 2018 Yayın	<%1
7	Submitted to (school name not available) Öğrenci Ödevi	<%1

ETİK KURUL İZİN YAZISI

Uyarı: Canlı denekler üzerinde yapılan tüm araştırmalar için Etik Kurul Belgesi alınması zorunludur.

☐ **Etik Kurul izni gerekmektedir.**

☒ **Etik Kurul izni gerekmemektedir.**

Başak IŞIK

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Başak IŞIK

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	
Doğum Tarihi	
Uyruğu	❒ T.C. ❒ Diğer:
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	
Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler